

# **Využití neuronových sítí v meteorologické predikci**

## **The Usage of Neural Networks in Meteorological Prediction**

## Zadání diplomové práce

Student:

**Bc. Jan Jurek**

Studijní program:

N2647 Informační a komunikační technologie

Studijní obor:

2612T025 Informatika a výpočetní technika

Téma:

**Využití neuronových sítí v meteorologické predikci**  
**The Usage of Neural Networks in Meteorological Prediction**

Zásady pro vypracování:

Algoritmy využívající přírodních principů se dnes začínají využívat stále častěji. Zajímavou oblastí jsou algoritmy založené na umělých neuronových sítích (Artificial Neural Networks), které napodobují chování neuronů v mozku, čímž přinášejí způsob jak učit počítače podobným způsobem, jako zvířata či lidé, a tak umožňuje na základě naučených informací např. predikci událostí.

Diplomant se v práci bude zabývat použitím neuronových sítí v oblasti krátkodobého předpovídání srážek na základě radarových dat.

Jednotlivé body práce jsou:

1. Nastudovat problematiku neuronových sítí a jejich použití v oblasti meteorologické predikce.
2. Vytvořit testovací prostředí pro testování různých typů neuronových sítí v oblasti predikce z radarových dat.
3. Implementace vybrané neuronové sítě.
4. Experimenty s neuronovou sítí v oblasti meteorologické predikce na umělých i reálných datech.
5. Provedení vyhodnocení experimentů.

Seznam doporučené odborné literatury:

[1] Jeff Heaton, Introduction to Neural Networks for C#, 2nd Edition, 2008

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Martinovič, Ph.D.**

Datum zadání: 16.11.2012

Datum odevzdání: 07.05.2014



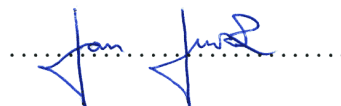
doc. Dr. Ing. Eduard Sojka  
vedoucí katedry



prof. RNDr. Václav Snášel, CSc.  
děkan fakulty

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě 18. dubna 2014

A handwritten signature in blue ink, consisting of stylized, cursive letters, is written over a horizontal dotted line.

Rád bych na tomto místě poděkoval především panu Ing. Janu Martinovičovi, PhD. za jeho vedení, cenné nápady a směřování při tvorbě této práce. Také bych rád poděkoval všem, kteří mi při tvorbě práce pomáhali udržet si jasnou vizi a pozitivní nadhled, protože ani bez nich by tato práce nevznikla.

## Abstrakt

Práce se zabývá krátkodobou predikcí srážek z radarových snímků pomocí umělých neuronových sítí. Představuje metodu získávání dat pro učení neuronových sítí a také metody pro ověření správnosti jejich předpovědí. Testování probíhá na neuronových sítích učených třemi přístupy: zpětným šířením chyby, zpětným šířením v čase v rekurentní síti a simulovaným žíháním. Cílem práce je prozkoumání těchto metod učení a určení jejich vlastností pro další zkoumání, nalezení vhodných parametrů nastavení neuronových sítí a ověření metody získávání dat na reálných radarových snímcích CZRAD poskytovaných ČHMÚ.

**Klíčová slova:** Neuronové sítě, krátkodobá predikce srážek, radarové snímky, metoda zpětného šíření, rekurentní síť, simulované žíhání

## Abstract

Thesis deals with nowcasting of precipitation from radar images using artificial neural networks. It presents method for obtaining data from radar images and also means for verification the accuracy of predicted precipitation. Tests are performed on neural networks trained by three approaches: backpropagation, backpropagation through time for recurrent networks and simulated annealing. The aim is to examine learning methods and determine their properties for further research, finding the most suitable parameter settings for learning and also to verify data obtaining method on actual radar images from CZRAD provided by Czech Hydrometeorological Institute.

**Keywords:** Neural networks, nowcasting, radar image, backpropagation, recurrent network, simulated annealing

## **Seznam použitých zkratk a symbolů**

NN	– Neural Network (Neuronová síť)
BP	– Backpropagation
RNN	– Recurrent neural network (Rekurentní síť)
BPTT	– Backpropagation through time
SA	– Simulated Anneling (Simulované žíhání)
ČHMÚ	– Český hydrometeorologický ústav

## Obsah

<b>1</b>	<b>Úvod</b>	<b>5</b>
1.1	Struktura práce . . . . .	5
<b>2</b>	<b>Neuronové sítě</b>	<b>6</b>
2.1	Biologický neuron . . . . .	6
2.2	Umělý neuron . . . . .	7
2.3	První umělý neuron (McCullochův) . . . . .	7
2.4	Perceptron . . . . .	8
2.5	Perceptronová síť . . . . .	11
<b>3</b>	<b>Algoritmy učení neuronových sítí</b>	<b>13</b>
3.1	Adaptační pravidlo perceptronu . . . . .	13
3.2	Backpropagation . . . . .	13
3.3	Rekurentní síť . . . . .	14
3.4	Simulované žíhání . . . . .	17
<b>4</b>	<b>Aplikace meteorologických předpovědí</b>	<b>19</b>
4.1	Využití radarových snímků (Irsko) . . . . .	19
4.2	Evoluční algoritmy . . . . .	21
<b>5</b>	<b>Použitá data a metoda</b>	<b>22</b>
5.1	Meteorologická data . . . . .	22
5.2	Zpracování dat pro učení . . . . .	23
5.3	Ověření předpovědi . . . . .	25
5.4	Rozdělení dat . . . . .	25
5.5	Implementace neuronových sítí . . . . .	27
<b>6</b>	<b>Testování</b>	<b>28</b>
6.1	Ověření metod na testovacím generátoru . . . . .	28
6.2	První testování a Wi-Fi rušení . . . . .	28
6.3	Rádus vzorku $r$ -point metody . . . . .	29
6.4	Topologie neuronových sítí . . . . .	32
6.5	Velikost učených snímků (trénovací množiny) . . . . .	33
6.6	Předpověď na menší oblasti snímku . . . . .	34
6.7	Předpověď s vyšším rozlišením než trénovaným . . . . .	35
6.8	Paměť a generalizace neuronových sítí . . . . .	36
6.9	Intenzivní srážky . . . . .	38
6.10	Skládání výsledků neuronových sítí . . . . .	40
<b>7</b>	<b>Závěr</b>	<b>44</b>
<b>8</b>	<b>Reference</b>	<b>45</b>

<b>Přílohy</b>	<b>46</b>
----------------	-----------

<b>A Ukázky předpovědí</b>	<b>47</b>
----------------------------	-----------



## Seznam tabulek

1	Hodnoty predikčních schopností genetického algoritmu, Zdroj [15] . . . .	21
2	Hodnoty naměřené na testovacích datech pro 2 budoucí snímky . . . . .	28
3	Hodnoty pro dva budoucí snímky při testování na reálných datech . . . .	29
4	Srovnání $F\text{-Score}$ pro $r = \{0, 1, 2\}$ . . . . .	31
5	Srovnání hodnot pro 1 a 2 vnitřní vrstvy . . . . .	32
6	Hodnoty předpovědi pro velikosti snímků se scale $\{3, 9\}$ . . . . .	33
7	Hodnoty pro testování nad výřezem radarového snímku pro scale $\{1, 3\}$ .	34
8	Srovnání $F\text{-Score}$ , $SampleE$ a $PointE$ pro zvětšené rozlišení předpovědi	35
9	Výsledky testu pro obdobnou, generalizovatelnou a neznámou situaci . .	36
10	Výsledky testu pro snímky s bouřkami . . . . .	38
11	Srovnání hodnot pro normální a provázané metody předpovědi . . . . .	41
12	Srovnání hodnot provázané metody předpovědi nad bouřkovými snímky	42

## Seznam obrázků

1	Zjednodušený model biologického neuronu . . . . .	6
2	McCullochův formální neuron . . . . .	7
3	Perceptron a úprava práhu na váhu . . . . .	8
4	Příklady aktivačních funkcí perceptronu . . . . .	9
5	Schopnosti perceptronu podle počtu vrstev . . . . .	10
6	Vícevrstvá neuronová síť . . . . .	11
7	Adaptace vah výstupní a vnitřní vrstvy pomocí BP . . . . .	15
8	Ukázka vícevrstvé rekurentní sítě, Zdroj [17] . . . . .	16
9	Složený snímek z Met Éireann Radar Service, Zdroj[18] . . . . .	20
10	Pozice a pokrytí radarů CZRAD na území ČR, Zdroj [20] . . . . .	22
11	Radarový snímek; výseče označují rušení Wi-Fi signálem . . . . .	23
12	Bod a rozdíl okolních bodů z předchozího snímku, pro $r = 1$ . . . . .	24
13	Vstupní a výstupní data pro jeden trénovací vzorek . . . . .	24
14	Úhrny srážek za rok 2012 a 2013 v mm, zdroj dat [21] . . . . .	25
15	Rozložení intenzity odrazivosti pro roky 2012 a 2013 . . . . .	26
16	Program pro získání a rozdělení intenzit ve snímcích . . . . .	26
17	Rozhraní pro práci s neuronovými sítěmi . . . . .	27
18	Graf porovnání $F-Score$ na rušených a vyčištěných snímcích . . . . .	30
19	Graf porovnání $SampleE$ a $PointE$ na rušených a vyčištěných snímcích . . . . .	30
20	Graf srovnání $F-Score$ pro $r = \{0, 1, 2\}$ . . . . .	31
21	Graf srovnání $SampleE$ a $PointE$ pro $r = \{0, 1, 2\}$ . . . . .	31
22	Grafy srovnání $F-Score$ a chyb pro síť s 2 vnitřními vrstvami . . . . .	32
23	Graf srovnání chyby snímku a bodu pro velikosti snímků se scale $\{3, 9\}$ . . . . .	33
24	Maska pro učení v plné velikosti snímku . . . . .	34
25	Graf srovnání chyby u výřezu snímku pro scale $\{1, 3\}$ . . . . .	35
26	Testované běžné oblačnosti . . . . .	36
27	Graf srovnání $F-Score$ testované situace ve 6.8 . . . . .	37
28	Graf srovnání chyb $SampleE$ a $PointE$ pro situace 12/2013 a 1/2013 . . . . .	37
29	Testované bouřkové situace . . . . .	38
30	Graf srovnání $F-Score$ testované situace s bouřkovými situacemi . . . . .	39
31	Graf srovnání chyb $SampleE$ a $PointE$ pro bouřkové situace . . . . .	39
32	Ukázka použití masky RNN a SA pro BP . . . . .	40
33	Hodnoty chyb $SampleE$ a $PointE$ pro provázané metody masky . . . . .	41
34	Hodnoty chyb provázaných metod nad bouřkovými snímky . . . . .	42
35	Předpověď běžné oblačnosti pomocí BP . . . . .	47
36	Předpověď běžné oblačnosti pomocí RNN . . . . .	47
37	Předpověď běžné oblačnosti pomocí SA . . . . .	47
38	Předpověď bouřkové oblačnosti pomocí BP . . . . .	48
39	Předpověď bouřkové oblačnosti pomocí RNN . . . . .	48
40	Předpověď bouřkové oblačnosti pomocí SA . . . . .	48
41	Kombinace předpovědí BP s RNN a SA u běžné oblačnosti . . . . .	49
42	Kombinace předpovědí BP s RNN a SA u bouřkové oblačnosti . . . . .	50

## 1 Úvod

Přírodní mechanismy se v technice stávají stále více populární a díky adaptaci miliony let vytvářených algoritmů a struktur se stávají vážnými kandidáty pro implementace ve výpočetní technice.

Jednou z nejstarších a původních aplikací přírodní struktury jsou neuronové sítě, respektive neurony, které tvoří mozkovou tkáň většiny živočichů. Jejich výhoda leží ve vysokém výpočetním výkonu a jednoduchém základním principu zachycení informace. Již relativně malé dítě [7] například dokáže velice jednoduše rozeznat od sebe kočku či psa na předloženém obrázku, něco pro co je potřeba složitý výpočetní algoritmus. Neuronové sítě se stejně jako lidský mozek učí a to je základní rozdíl od klasického přístupu, kdy je tvořen pro problém algoritmus. Neuronová síť [17] se problém naučí z předložené trénovací množiny bez potřeby znát algoritmus, kterým je množina popsána.

Neuronové sítě jsou schopny tzv. generalizace [3], což znamená, že jejich výsledky nebudou vždy tak přesné jako klasické výpočetní metody, ale budou schopny na základě podobných vstupů získat odpověď i tam, kde by klasické výpočetní algoritmy mohly selhat.

Tyto vlastnosti se velmi hodí při predikci, kterou se také zabývá tato práce. Konkrétně se zaměřuje na krátkodobou predikci meteorologických radarových snímků na základě dat z CZRAD [20].

Cílem práce je nejen ukázat a porovnat schopnosti predikce jednotlivých učebních metod a neuronových sítí obecně, ale také stanovení vhodného nastavení parametrů učení a topologie neuronové sítě pro tyto predikce. Mimo jiné práce také demonstruje schopnost generalizace předpovědi nad neznámými daty a definuje dílčí metody pro porovnání míry správnosti predikce srážek na předpovězených snímcích.

### 1.1 Struktura práce

V kapitole 2 je popsán základní princip umělých neuronových sítí a jejich vývoj. Kapitola 3 pak představuje jednotlivé způsoby učení, které byly zvoleny pro otestování v této práci. Patří mezi ně základní učební algoritmus backpropagation (dále jen BP) popsáný v sekci 3.2, simulované žíhání (dále jen SA z anglického Simulated Annealing) popsané v sekci 3.4 a zpětné šíření v čase v rekurentní síti (sekci 3.3), která je speciální aplikací neuronových sítí zachycující časový kontext.

Následující kapitola 5 popisuje použitá radarová data, jejich selekci, způsob, kterým budou radarové snímky zpracovány do podoby vhodné pro učení neuronových sítí (odstavec 5.2.1) a také mechanismy pro vyhodnocení míry přesnosti předpovědi oproti skutečnosti (sekce 5.3).

Hlavní část práce, popsaná v kapitole 6, se zabývá testováním implementovaných učebních metod nejprve na testovací sérii a pak na reálných radarových snímcích a nalezením ideálních nastavení, při kterých se síť učí přijatelně rychle s uspokojivými výsledky. Sekce 6.10 popisuje postup, kterým je možné zlepšit předpověď skládáním výsledků sítí naučených jednotlivými metodami. Výsledky provedených testů jsou následně shrnuty v závěru diplomové práce (kapitola 7).

## 2 Neuronové sítě

Neuronovou sítí [10] se u savců nazývá množina neuronů propojených mezi sebou synapsemi, jejichž vazby jsou různě silné a umožňují zapamatování určitého vjemu, ať už máme na mysli reflex, vizuální podnět či vzpomínku. Jako taková je tato struktura komplikovanější tím, že celou její funkci ovlivňuje mnoho chemických faktorů, jejichž plného porozumění ještě není dosaženo.


Implementace umělé neuronové sítě se tedy zaměřuje zejména na její základní jednotku - neuron.

V textu práce se bude mnohokrát objevovat pojem neuron a neuronová síť. Pokud nebude blíže upřesněno, zda se jedná o umělou či biologickou variantu, je tím myšlen neuron či neuronová síť umělého charakteru.

### 2.1 Biologický neuron

Biologický neuron (viz obrázek 1) je základní stavební jednotkou biologické neuronové sítě. Spojení skupiny těchto neuronů umožňuje vytvoření struktury, která je schopna se naučit a zapamatovat si vjem či určitou schopnost, ať už jsou to vrozené schopnosti (DNA, reflexy) či schopnosti naučené během života.

Právě první zmíněné, tedy vrození nastavení vah synapsí, je jedna z největších předností biologických neuronových sítí. Tyto váhy se totiž předávají a vylepšují již po mnoho milionů let. Z tohoto hlediska mohou svou přesností umělé neuronové sítě konkurovat jen na pečlivě zvolené podmnožině problémů. Pro zlepšení učení [19] se ale i v umělých neuronových sítích provádí optimalizace nastavení počátečních vah na množinu problému.



Obrázek 1: Zjednodušený model biologického neuronu

Každý neuron přijímá signály přes dendriny odkud vstupují do těla neuronu, kde dojde k sumaci signálů. Pokud tato suma přesáhne prahovou hodnotu daného neuronu,

vyšle signál po axonovém vlákně do dalších neuronů. Na konci se axonového vlákno dělí na mnoho synapsí, které jsou dvojího druhu. Jedny signál zesilují (excitují) a druhé jej naopak zeslabují (inhibují). Odtud signál přechází do dendrinů dalších neuronů či přes nervy dále v nervové soustavě. Neuron jako takový je schopen zpracovat velké množství signálů (vstupů) a také svůj signál (výstup) předat do mnoha dalších neuronů.

To, že signál některého neuronu má větší váhu, určuje váha synapse a síť se učí právě nastavením těchto vah na hodnoty, které ve výsledku dodají kýžený stimul na konci dráhy informace. Tyto poznatky byly využity pro definování pravidel a způsobu učení umělých neuronů, a tím také struktur z nich sestavovaných - umělých neuronových sítí.

## 2.2 Umělý neuron


Ačkoliv základní princip šíření signálu v biologických neuronech se zdá být triviální, proces samotného učení, který ještě jako takový není úplně rozkryt, není jednoduché převést do jeho počítačového ekvivalentu. Výzkum neuronových sítí probíhá již od poloviny 20. století a modely, které v současnosti popisují umělý neuron, funkci jeho biologického předobrazu jen aproximují.

## 2.3 První umělý neuron (McCullochův)

První formální definici umělého neuronu představil v roce 1943 [12] W. S. McCulloch spolu s W. Pittsem. V práci se snažili dokázat, že je možné nasimulovat Turingův stroj konečným synchronním polem těchto formálních neuronů.

McCullochova definice neuronu je binární prahový neuron, neboť do něj vstupují binární informace, tzn. buď je vstup excitační (1) a přispívá tak do sumy +1 nebo je inhibiční (0) a do sumy přispívá -1. Pokud suma vstupů překročí definovaný práh neuronu, je tento excitován na hodnotu 1, jinak je inhibován (0). Model McCullochova neuronu a ukázka některých funkcí je na obrázku 2.

Ačkoliv je tento model ve své podstatě funkční, má oproti biologickému modelu několik podstatných omezení. Má skokovou odpověď, zatímco biologické neurony mají odpověď spojitou. Reálný neuron navíc produkuje sled pulsů, zatímco v tomto modelu je generován vždy jeden o stejné hodnotě. Reálné neurony rovněž nejsou nijak synchronizovány.



Obrázek 2: McCullochův formální neuron

## 2.4 Perceptron


Modelem umělého neuronu, který je do dnes v neuronových sítích používán je perceptron, jež roku 1957 definoval F. Rosenblatt [13]. Perceptronem se nazývá jak samotný neuron, tak i síť (jedno i vícevrstvá) s dopřednými vazbami tvořena z těchto perceptronů, která bude popsána v kapitole 2.5.

Na rozdíl od McCullochova neuronu do perceptronu přicházejí signály (viz obrázek 3) jako reálná čísla, která jsou vynásobena hodnotou vah synapsí, jejichž hodnota je také reálná. Váhy synapsí určují svou hodnotou významnost vstupu. Tyto vynásobené impulsy vstupů jsou sečteny a je od nich odečtena hodnota práhu neuronu. Na tuto sumu je aplikována tzv. aktivační funkce  $f$ , která určí hodnotu výstupu neuronu. Ta je tedy určena následující obecnou rovnicí:

$$y = f\left(\sum_{i=1}^n x_i w_i - \theta\right)$$

Pro formální zjednodušení rovnice se prahová hodnota neuronu nahrazuje vstupem  $x_0 = -1$  a váhou  $w_0 = \theta$ , což zjednoduší předpis funkce tak, že jej lze přepsat na skalární součin vektorů  $\vec{x}$  a  $\vec{w}$ :

$$y = f\left(\sum_{i=0}^n x_i w_i\right) \Rightarrow y = f(\vec{x}\vec{w})$$



Obrázek 3: Perceptron a úprava práhu na váhu


Podle druhu aktivační funkce se perceptrony dělí na dva základní typy: skokové a spojitě. Spojitě se pak ještě dále dělí na lineární a nelineární.

### 2.4.1 Prahový perceptron

Prahový perceptron je popsán skokovou aktivační funkcí (viz obrázek 4a) jejímž předpisem je:

$$f(n) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

Výstup tohoto neuronu je tedy 1 v případě kdy součet vstupů přesáhne hodnotu 0, jinak bude na jeho výstupu vždy hodnota 0. Tento průběh je v podstatě shodný s výstupem McCullochova neuronu.



Obrázek 4: Příklady aktivačních funkcí perceptronu

### 2.4.2 Lineární separabilita


Jednoduchý perceptron je sám o sobě schopen rozhodovat pouze lineárně separovatelné úlohy, tedy úlohy, které umožňují rozdělit množinu vstupů pomocí nadroviny (v dvou-rozměrném zobrazení přímkou) na dvě třídy (viz obrázek 5a). Jedna z nich odpovídá excitaci neuronu (1), druhá jeho inhibici (0) [17].

Mezi takovéto úlohy patří např. AND či OR, ale už ne funkce XOR. XOR je zvláštním případem paritní funkce vracující hodnotu 1, pokud je počet jedničkových bitů lichý. V ostatních případech vrací 0. Jedná se o jeden z nejtěžších problémů [10], který lze neuronovým sítím předložit, protože neuronová síť musí po každé změně vstupu měnit svou hodnotu.

Tento problém řeší vícevrstvé neuronové sítě, které umožňují pomocí skládání jednotlivých perceptronů ve vrstvách určit množinu pomocí konvexního polygonu a i jakoukoliv další množiny prvků.

### 2.4.3 Spojitý perceptron

Nezákladnějším typem spojitého perceptronu je lineární perceptron, který díky své funkci není nutné učit, avšak provádí pouze lineární zobrazení. Pro výpočet vah [10] je navíc potřeba, aby všechny vzory byly navzájem lineárně nezávislé, čehož se docílí pouze tím, že bude vzorů méně než neuronů v síti.



Obrázek 5: Schopnosti perceptronu podle počtu vrstev

Dalším a zároveň nejpoužívanějším typem spojitého perceptronu je perceptron nelineární, který využívá tzv. saturační funkce. Ta sumu vstupů převede do intervalu  $\langle 0, 1 \rangle$  (respektive  $\langle -1, 1 \rangle$ ) tak, že v blízkosti nuly potenciál neuronu prudce stoupá (respektive klesá), zatím co v intervalech vzdálenějších od nulové hodnoty se potenciál mění už jen nepatrně.

Nejklasičtějšími saturačními funkcemi jsou sigmoida (obrázek 4c) a hyperbolický tangent (4d), které jsou definovány následovně:

$$S(x) = \frac{1}{1 + e^{-\lambda x}}, \quad \tanh(x) = \frac{e^{\lambda 2x} - 1}{e^{\lambda 2x} + 1},$$

kde  $\lambda$  představuje strmost sigmoidu.

Z výše popsaných vzorců (a průběhů funkcí) vyplývá, že v případě, kdy se vnitřní potenciál (suma) neuronu blíží  $+\infty$ , dochází k úplné excitaci neuronu  $S(x) = 1$  ( $\tanh(x) = 1$ ). Pokud se naopak vnitřní potenciál blíží  $-\infty$ , dochází k úplné inhibici neuronu -  $S(x) = 0$  ( $\tanh(x) = -1$ ).

Nelineární perceptron se svou stavbou nejvíce podobá biologickému neuronu a je využit především při stavbě vícevrstevných neuronových sítí [17].




## 2.5 Perceptronová síť

Zřejmě nejrozšířenějším užitím spojitého perceptronu je vícevrstvá neuronová (perceptronová) síť. Ta je tvořena, jak vyplývá z obrázku 6, alespoň třemi vrstvami. Vstupní vrstvou, na kterou jsou přivedeny signály, výstupní vrstvou, ve které reaguje síť na vstup odpovídající výstupní informaci, a minimálně jednou vnitřní vrstvou. Mezi neurony sousedních vrstev pak dochází k jejich úplnému propojení.

Pro většinu praktických řešení není potřeba využívat více než jednu vnitřní vrstvu (obrázek 5b). Vstupní vrstva se někdy při určování velikosti sítě nezapočítává, protože její neurony jsou vždy excitovány a přivádějí signály do vyšší vrstvy. V tomto kontextu se pak třívrstvémi sítěmi myslí síť s dvěma vnitřními (skrytými) vrstvami.

Třívrstvá (respektive čtyřvrstvá, viz obrázek 5c) síť je schopna aproximovat libovolné reálné zobrazení mezi prostorem vstupů a výstupů tzn., že pro libovolné zobrazení  $R^n \rightarrow R^m$  existuje třívrstvá síť, která jej popisuje [10]. V současnosti neexistuje teoretický důvod proč používat více než 2 vnitřní vrstvy [7].



Obrázek 6: Vícevrstvá neuronová síť

### 2.5.1 Dopředné šíření signálu

Ve vícevrstvé neuronové síti je excitace výstupů dosaženo tzv. dopředným šířením (feed-forward) signálu.

Nejprve jsou na vstupní vrstvu přivedeny hodnoty vstupů v intervalu dle aktivační funkce  $\langle 0, 1 \rangle$  či  $\langle -1, 1 \rangle$ . Tyto excitace jsou pomocí vazeb přeneseny do vnitřní vrstvy sítě. Přes váhy synapse (dále jen váhy) na vstupech vyšší vrstvy jsou tyto signály zesíleny či zeslabeny:

$$z_j = \sum_{i=1}^o x_i w_{ij},$$

kde  $o$  je množina všech neuronů předcházející vrstvy a  $z_j$  je suma hodnot  $x_i$  nižší vrstvy, které do neuronu vstupují přes synaptické váhy  $w_{ij}$ .

Každý neuron provede sumu těchto svých vstupů a výsledek pošle přes aktivační funkci  $f(z_j)$  opět do všech neuronů vyšší vrstvy. Tento proces se opakuje pro každou vrstvu, než je dosaženo výstupní vrstvy, kde z výstupních neuronů získáme excitační stavy výstupů neuronové sítě.

Tímto postupem jsme vlastně získali reakci neuronové sítě na vnější podnět. Stejným způsobem probíhá šíření signálu i v biologické neuronové síti. Vstupem v ní mohou být např. signály z nosní sliznice a výstupem rozpoznání čichového vjemu, známého pachu či vůně.

### 3 Algoritmy učení neuronových sítí

Neuronové sítě můžeme rozdělit podle topologie na dva typy: na sítě s dopředným vazbami a sítě zahrnující i jisté rekurentní vazby. Pro otestování byly zvoleny dvě metody učení pracující s dopřednou neuronovou sítí a dále pak rekurentní síť, která obsahuje neurony s rekurentními vazbami.

Učení neuronových sítí se dá rovněž rozdělit na učení bez učitele a učení s přítomností učitele. Metody použité v této práci se zaměřují na učení s učitelem. Pro tento typ učení je potřeba trénovací množiny. Váhy synapsí se upravují rozdílem výstupu sítě a skutečného požadovaného výstupu.

Cílem tohoto učení není jen správné přiřazení výstupů k požadovaným vstupům, ale také schopnost generalizace, tedy aby byla neuronová síť schopna neznámému vstupu přiřadit přijatelný výstup [3, str. 51]. Ačkoli není tento způsob učení vlastní biologické síti, je velmi účinný a v současnosti je jeho fungování ověřeno na velkém množství zejména aproximačních a predikčních úloh.

#### 3.1 Adaptační pravidlo perceptronu

Váhy jednoduchého perceptronu (viz kapitola 2.4) jsou podle tohoto pravidla adaptovány tak, aby rozdíl mezi skutečným a požadovaným výstupem byl co nejmenší.

Nejprve jsou všechny hodnoty váhového vektoru  $\vec{w}$  inicializovány malými náhodnými čísly. Následně je pak neuronu předložen vstup trénovací množiny a je vypočten rozdíl požadovaného a skutečného výstupu podle vzorce:

$$\Delta = d(t) - y(t) ,$$

kde  $\Delta$  představuje chybu odezvy neuronu,  $d(t)$  požadovanou hodnotu a  $y(t)$  hodnotu dodanou perceptronem. S využitím této chyby následně upravíme váhy pro následující krok podle:

$$w_i(t+1) = w_i(t) + \eta \Delta x_i(t) ,$$

kde  $0 \leq \eta \leq 1$  představuje koeficient učení ovlivňující míru adaptace. Jestliže je v následujícím kroku  $\Delta$  nulová, nebo menší než určený práh chyby, je učení úspěšně ukončeno.

#### 3.2 Backpropagation

Metoda zpětného šíření je základní a nejpoužívanější (v 80% případů [16, str. 35]) metoda adaptace vah dopředných neuronových sítí. Jak již její název napovídá, metoda (na rozdíl od dopředného šíření) adaptuje změny od výstupní vrstvy směrem ke vstupní.

Podstata BP spočívá ve hledání minima funkce chyby  $E$ , která je formálně dána tímto předpisem:

$$E = \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^m (y_k - o_k)_j^2 ,$$

kde  $y_k$  je odezva neuronové sítě na předložený vzor,  $o_k$  je požadovaná odezva výstupu pro dané vstupy,  $p$  je celkový počet vzorů trénovací množiny a  $m$  počet neuronů výstupní vrstvy.

Tato chyba je snižována pomocí gradientní metody úpravou synaptických vah neuronů. Algoritmus začíná předložením prvního vzoru sítí a provedením dopředného šíření. K neuronům ve výstupní vrstvě (viz 7a) je vypočten rozdíl hodnoty oproti požadované hodnotě pro vstupní vzor:

$$\delta_k = (o_k - y_k)f'(z_k), \quad \text{kde} \quad z_k = \sum_{j=1}^n x_j w_{jk},$$

$f'(z_k)$  je derivací sumy výstupů množiny neuronů  $n$  nižší vrstvy přispívajících přes váhy do neuronu  $k$ .  $\delta_k$  představuje potřebnou změnu vah, která bude dále upravovat synaptické váhy vstupů neuronů výstupní vrstvy. Ke každému neuronu ve vnitřní vrstvě je přiřazena suma jeho  $\delta$  vstupů, tedy neuronů nacházejících se v nižší vrstvě:

$$\delta_j = \sum_{k=1}^m \delta_k w_{jk} f'(z_j), \quad \text{kde} \quad z_j = \sum_{i=1}^o x_i w_{ij},$$

$\delta_j$  představuje potřebnou změnu vah neuronu  $j$ -té vnitřní vrstvy, která při dopředném šíření přispívá přes váhy  $w_{jk}$  svou hodnotou do vyšší vrstvy. Množina  $o$  představuje neurony předcházející vrstvy.

Výše popsaný výpočet  $\delta$  se provede pro všechny vnitřní vrstvy sítě. Po stanovení všech  $\delta$  jsou upraveny jednotlivé váhy ve vrstvách. Stanovení váhy pro výstupní vrstvu je dáno vzorcem:

$$w_{jk}(t+1) = w_{jk}(t) + \eta \delta_k y_j + \mu [w_{jk}(t) - w_{jk}(t-1)]$$

a váhy vnitřních vrstev:


$$w_{ij}(t+1) = w_{ij}(t) + \eta \delta_j y_i + \mu [w_{ij}(t) - w_{ij}(t-1)],$$

kde  $\eta$  představuje koeficient učení sítě, který určuje jak velká část  $\delta$  hodnoty přispěje ke změně váhy. Konstanta  $\mu$ , jejíž rozsah je  $\langle 0, 1 \rangle$ , je koeficientem vlivu vah předchozího kroku.

Stanovení hodnot  $\eta$  a  $\mu$  je důležité pro efektivní adaptaci sítě. Jejich nastavení je však ve většině případů věcí experimentů [17], neboť prakticky neexistuje žádné exaktní pravidlo, které by tento problém mohlo vyřešit.

### 3.3 Rekurentní síť

Běžná dopředná neuronová síť mapuje vstupy, přivedené na vstup sítě, na výstupy bez závislosti na kontextu. Stejný stimul tedy vede vždy ke stejné odezvě sítě, což se nehodí pokud na posloupnosti vstupních dat záleží. V běžné dopředné neuronové síti se zavedení kontextu řeší zvýšením počtu vstupních neuronů tak, aby bylo možné kontext popsat v



Obrázek 7: Adaptace vah výstupní a vnitřní vrstvy pomocí BP

jednom učebním vzorku. To vede k značnému zvětšení výsledné sítě a tím i k pomalému učení a konvergenci.


Rekurentní neuronová síť (dále také RNN z anglického Recurrent Neural Network) je rozšířením základní dopředné neuronové sítě, která umožňuje časový kontext předcházejících kroků promítnout i do stimulů aktuálních. Posloupnost vstupních dat tedy bude mít vliv na výsledek učení sítě bez nutnosti upravovat topologii sítě výše zmíněným způsobem. Rekurentnost je tedy jakási zpětnovazební smyčka, která je vlastní i biologickým neuronům. Z matematického pohledu jsou RNN dynamickými systémy [8], tedy systémy jejichž stav a chování je závislé na čase.

RNN pro adaptaci opět využívá gradientní metodu backpropagation. Ta ale nemůže být použita přímo, protože předávání chyby v BP předpokládá, že spojení mezi neurony neobsahují cykly, tedy zpětná spojení. Učení musí probíhat dávkovým způsobem, kdy se změny vah nejprve akumulují pro všechny vzory sekvence a až poté jsou provedeny úpravy vah.

Jinými slovy, oproti předcházejícímu modelu se signál nešíří jen od vstupní vrstvy směrem k vrstvě výstupní, ale dochází i ke zpětnovazebnímu přenosu informace z předchozích předkládaných vzorů. Stejně tak i propagace chyby sítě se šíří nejen od výstupu k vstupu, ale také od posledního trénovaného vzoru k prvnímu. Pro tento přenos jsou v síti zavedeny tzv. rekurentní neurony, jak je naznačeno na obrázku 8. Tato metoda se nazývá zpětnovazební šíření v čase (dále BPTT z anglického Backpropagation through time).

Z tohoto popisu vyplývá, že gradientní metodou BP je nutné minimalizovat tuto výslednou chybu:

$$E_s(t) = \sum_{n=1}^T E(t+n), \quad \text{kde} \quad E(t+n) = \frac{1}{2} \sum_{k=1}^m (y_k(t+n) - o_k(t+n))^2,$$



Obrázek 8: Ukázka vícevrstvé rekurentní sítě, Zdroj [17]

kde  $\sum E(t+n)$  představuje sumu chyb rozdílů výsledné hodnoty oproti hodnotě požadované v časových intervalech vzoru sekvence  $t, t+1$  až  $t+n$ . Pro poslední vzorek sekvence je hodnota  $E(t+n) = 0$ .

Jako první je pro vzory provedeno dopředné šíření od prvního až po poslední časový vzor ( $t = 1, \dots, T$ ) a výsledky jsou uloženy.

Následně je pak zpětným šířením propagována chyba vnějšího neuronu posledního časového vzoru ( $n = T$ ) pro vnější vrstvu:

$$\delta_k(T) = (o_k(T) - y_k(T))f'(z_k(T))$$

pro vnitřní vrstvy v čase T:

$$\delta_j(T) = \left[ \sum_{k=1}^m \delta_k(T)w_{jk} \right] f'(z_j(T))$$

Pro vrstvy z předchozích vzorů sekvence pak platí pro vnější vrstvu:

$$\delta_k(t) = \left[ o_k(t) - y_k(t) + \sum_{j=1}^n \delta_j(t+1)w_{jk}^{rec} \right] f'(z_k(t))$$

a vnitřní vrstvy:

$$\delta_j(t) = \left[ \sum_{k=1}^o \delta_k(n)w_{jk} + \sum_{k=1}^o \delta_k(n+1)w_{jk}^{rec} \right] f'(z_j(t))$$

Tyto vypočtené rozdíly se využijí ke změně vah. Akumulují se pro každou jednotlivou vazbu a jednotlivý časový krok sekvence od posledního po první. Změny jsou pak

aplikovány na neuronovou síť a jsou upraveny jednotlivé váhy ve vrstvách. Pro výstupní vrstvu jsou upraveny podle vzorce:

$$w_{jk} = w_{jk} + \eta \sum_{t=1}^T \delta_k y_j,$$

váhy vnitřních vrstev podle:

$$w_{ij} = w_{ij} + \eta \sum_{t=1}^T \delta_j y_i,$$

a váhy rekurentních neuronů vzorci:

$$w_{jk}^{rec} = w_{jk}^{rec} + \eta \sum_{t=1}^T \delta_k y_j(t-1), \quad \text{resp.} \quad w_{ij}^{rec} = w_{ij}^{rec} + \eta \sum_{t=1}^T \delta_j y_i(t-1)$$

Z výše uvedeného vyplývají omezení rekurentní sítě. Pokaždé, když zvětšíme počet časových vzorků v sekvenci, zvětší se paměťová i časová náročnost výpočtu. Navíc velikost této sekvence je omezena, jelikož pro velké časové úseky se vytrácí hodnota gradientu [2], kdy se průchodem každou vrstvou neuronové sítě v čase chyba zmenšuje tak, až zmizí úplně.

Opakovaným učením série dat se pomalu posouvá komplexní nelineární dynamický systém (myšleno neuronová síť) v prostoru parametru (váhy neuronů), čímž se síť přibližuje k bodům bifurkace<sup>1</sup>, ve kterých se může její chování výrazně změnit (s tím souvisí i výše zmíněné vytrácení gradientu). Díky tomu může chyba v kritických místech, při překročení hranice (bodu bifurkace), nenávratně narůst a znemožnit tak naučení sítě [4].

Na rozdíl od učení běžné dopředné sítě není u BPTT garantována konvergence do lokálního minima chyby [8]. To u dopředných sítí nemůže nastat, neboť ty realizují funkce, ne dynamický systém.

### 3.4 Simulované žíhání

Simulované žíhání bylo vyvinuto v polovině 70 let 20. století S. Kirkpatrickem [9] a několika dalšími badateli. Původně bylo vyvinuto k lepší optimalizaci návrhů elektronických obvodů pomocí simulace skutečného procesu žíhání z metalurgie.

Žíhání v metalurgii je proces prudkého zahřátí ocele a následně pomalého ochlazování, které má za následek zatvrdnutí materiálu v kvalitněji postavené krystalové mřížce, kde se nachází méně nerovností a tím se zvýší tvrdost materiálu.

Při hledání ve stavovém prostoru může nastat situace, kdy běžný algoritmus uvázne v lokálním minimu. Simulované žíhání, podobně jako žíhání ocele na začátku, díky vysoké teplotě umožňuje vstupům provádět změny hodnoty na velkém rozsahu, což právě může být cestou z lokálního minima [5]. Postupem času se teplota (a tím i rozsah možných změn

<sup>1</sup>Bodem bifurkace je v matematice popsán bod, ve kterém funkce ztrácí buď diferencovatelnost, nebo spojitost, nebo obojí – současně.

hodnot) snižuje. Simulované žíhání tedy mnohdy může vést k lepšímu řešení problému než běžný prohledávací algoritmus.

Vzorec pro určení koeficientu snižování teploty (ochlazování) v daném počtu cyklů je následující:

$$step = e^{\frac{\ln(\frac{s}{e})}{c-1}},$$

kde  $s$  je počáteční teplota,  $e$  je koncová teplota a  $c$  je počet cyklů, ve kterých bude teplota snižována. Tímto koeficientem se bude počáteční teplota v každém kroku cyklu násobit a tím snižovat hodnoty, které jsou k řešení přičítány (respektive odečítány).

### 3.4.1 Simulování žíhání a dopředná síť

Použití simulovaného žíhání v dopředné síti je jen aplikací výše popsaného postupu na váhy neuronů sítě.

Nejprve je stanovena chyba sítě  $E$  podle gradientu BP (viz 3.2) a síť je uložena jako nejlepší řešení. Následuje proces žíhání, kdy se přičtením náhodné hodnoty, jejíž velikost se mění podle teploty, změny nastavení vah a následně je opět vypočtena chyba sítě. Pokud je tato chyba nižší, než chyba dříve vypočtená, stává se upravená síť nejlepším řešením. Cyklus pokračuje do té doby, než teplota dosáhne teploty koncové.

Tento postup lze opakovat v několika iteracích žíhání, dokud například chyba sítě neklesne pod požadovanou mez či není dosaženo maximálního počtu iterací, stejně jako při trénování sítě pomocí BP.



## 4 Aplikace meteorologických předpovědí

Neuronové sítě se v meteorologických předpovědích využívají převážně při vyhodnocování vývoje dat z měřících stanic.

Kumar Abhisheka[1] ve své práci s neuronovými sítěmi, předpovídajícími teplotní vývoj, zaměřuje na parametry velikosti sítě nutné pro dostatečnou schopnost generalizace nad dodanými daty. Také poukazuje na nebezpečí přeučení sítě, způsobené příliš vytrvalým učením na trénovací množině. Další článek [6] zabývající se teplotou dokazuje předpovědní schopnosti vícevrstvé neuronové sítě, vztažené k ročním obdobím v okolí města Kermanshah v Iránu.

Článek [14] rozebírá použití neuronových sítí v předpovědi srážkových úhrnů v okolí řeky Sieve v Apeninách. Data použitá pro předpovědi byla průtok řeky v intervalu 1–6 h a dále údaje o srážkách a teplotách z 12 měřících stanic. Ve studii byly mimo jiné vyzkoušeny dva přístupy předpovědi. Prvním je extrapolace předpovědi z již předpovězené hodnoty, tzn. že síť byla naučena na předpovědi jednoho budoucího snímku a pro delší předpověď ji opět byl snímek jí předpovězený předložen. Druhá metoda počítala s naučením na více budoucích snímcích. Jako lepší se ukázala druhá metoda, neboť chyba předpovědi sítě se výrazným způsobem přenášela i do následující předpovědi.

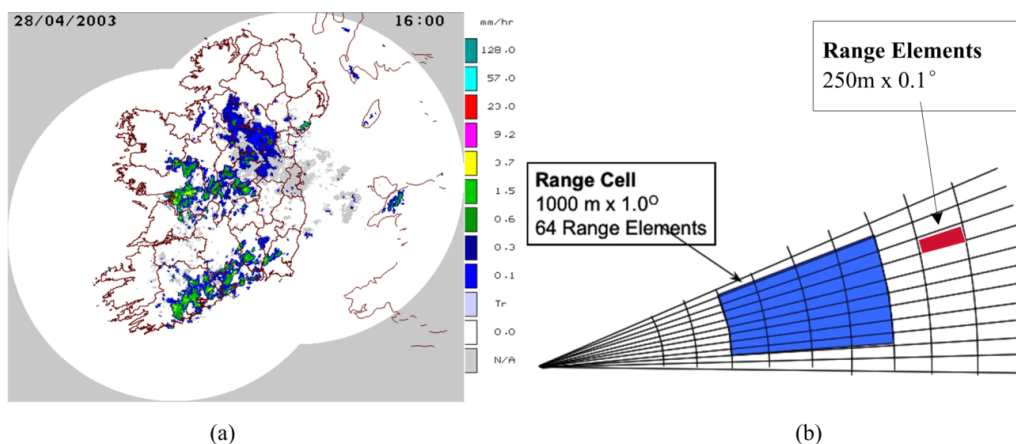
Další aplikace je ukázána na předpovědi bouřek v okolí města Kalkata [11] v období monzunů. Pro předpověď byly využity hodnoty teplot a relativních vlhkostí. Ve studii se povedlo získat pomocí umělých neuronových sítí relevantní hodinové předpovědi pro teplotní a vlhkostní charaktery v modelech 1, 3 a 24 h časového pásma před bouří.

### 4.1 Využití radarových snímků (Irsko)

Studie [18] se zabývala krátkodobou předpovědí srážek za použití radarových snímků z Met Éireann Radar Service pomocí morfologických metod. Met Éireann Radar systém využívá dvou radarových stanic v Dublinu a Shannonu. Na obrázku 9a je vidět spojení detekcí do společného radarového snímku. Radary sbírají data každých 15 minut v okolí 240 km s rozlišením 1 km na pixel.

Analýza snímku z radarů probíhala následovně: ze snímku bylo odstraněno pozadí, tedy všechny data nesouvisející s vodními masami. Následně byla nad daty provedena binarizace a odstranění přebytečných nezajímavých dat. Pomocí této masky byly z původního snímku načteny vodní masy i s identifikací různých intenzit deště, které byly využity pro získání centra a intenzit deště. Na binarizovaném obrazu vodní masy byly detekovány hrany, což umožnilo analyzovat celkový tvar.

Při získávání dat byly vytvořeny dvojice  $\{P_{hy}, M_{or}\}$ , kde  $P_{hy}$  popisuje fyzikální vlastnosti vodních mas jako směr pohybu, rychlost a zrychlení a  $M_{or}$  morfologické vlastnosti, jako intenzita srážek, jejich rozložení a další. Tyto dvojice unikátně popisovaly vodní masy tak, aby je bylo možné identifikovat v časových snímcích.



Obrázek 9: Složený snímek z Met Éireann Radar Service, Zdroj[18]

#### 4.1.1 Ověření přesnosti předpovědi

Přesnost předpovědi byla ve studii ověřena pomocí následujících rovnic pro *Precision* (pozitivní prediktivní hodnota) a *Recall* (sensitivita):

$$Precision = \frac{R/R}{R/R + R/NR}$$

$$Recall = \frac{R/R}{R/R + NR/R}$$

$R/R$  je číslo předpovídaného deště, který skutečně spadl,  
 $R/NR$  je číslo představující poměr deště, který měl spadnout a nespádl a  
 $NR/R$  je opak předchozího, tedy poměr mezi tím kde déšť nespádl a měl.

Výsledné ohodnocení předpovědi je provedeno dle následující rovnice pro vážený průměr:

$$F-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Metoda podávala nejlepší předpovědi v krátkodobé horizontu. Omezení, které technologické provedení radarů přináší, snižovalo předpovědní schopnost v oblastech vzdálenějších od míst s radarovými stanicemi.

## 4.2 Evoluční algoritmy

Lukáš Vitásek [15] se ve své diplomové práci zabývá předpovědí radarových snímků dopředných neuronových sítí adaptovaných pomocí evolučních algoritmů.

V práci je nejprve rozebrán základní princip několika evolučních algoritmů. Nad těmito algoritmy je pak prováděn testování na testovacím generátoru oblačnosti. Po porovnání výsledků jednotlivých metod učení byla vybrána nejlepší. Tou byl genetický algoritmus, který používá reprezentaci genů s plovoucí desetinnou čárkou.

Nad testovacími daty generátoru dosahoval tento algoritmus pro první snímek hodnot  $F\text{-Score}$  v čase  $t + 1$  mezi 0.9 až  $\approx 1$ . Nad reálnými radarovými snímky české republiky tato predikční schopnost klesla na  $\approx 0.6$ .

	$Q_1$	$Avg$	$Q_3$
$Precision_{t+1}$	0.40	0.6	0.93
$Precision_{t+2}$	0.34	0.63	0.91
$Recall_{t+1}$	0.67	0.77	0.96
$Recall_{t+2}$	0.57	0.7	0.94
$F\text{-Score}_{t+1}$	0.60	0.76	0.95
$F\text{-Score}_{t+2}$	0.54	0.72	0.94

Tabulka 1: Hodnoty predikčních schopností genetického algoritmu, Zdroj [15]

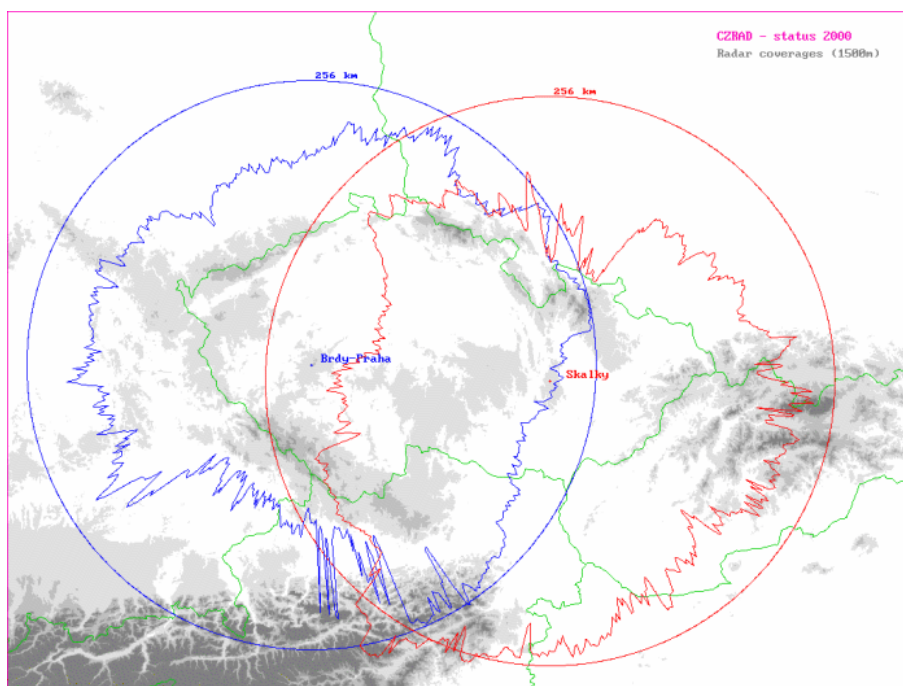
## 5 Použitá data a metoda

Pro učení neuronových sítí v kapitole 6, zabývající se experimenty, byly využity radarové snímky České republiky, pro jejichž zpracování byla definována tzv. *r*-point metoda detailněji popsaná dále v kapitole 5.2.1. Pro výběr situací byl získán dostatečně velký vzorek snímků, a tak mohlo učení probíhat na datech z roku 2012 a jejich ověřování na datech ze stejných období roku následujícího.

### 5.1 Meteorologická data

Pro otestování předpovědí na reálných datech byly využity radarové snímky CZRADu ČHMU volně dostupné pod CC3 licenci, průběžně sbírané od června roku 2011.

Meteorologický radiolokátor umožňuje detekci výrazné srážkové oblačnosti (bouřky do cca 250 km). Mohou být použity pro odhad okamžitých intenzit srážek do cca 150 km od radaru. Princip funkce radaru je založen na zpětném rozptylu mikrovln (cm-vln) na vodních kapkách a ledových krystalcích ve srážkách a oblačnosti. Vysílač generuje krátké vysokoenergetické pulsy elektromagnetického vlnění, které anténa vyzařuje v podobě úzkého svazku do atmosféry. Část energie se odrazí (přesněji: zpětně rozptýlí) od cílů meteorologických (srážky) či jiných (terén, letadla apod.). Část zpětně rozptýlené energie je zachycena anténou a zpracována přijímačem radaru. Podle polohy antény (azimut, elevace) a času mezi vysláním a příjmem pulsu se určuje poloha cíle. Množství odražené energie je úměrné intenzitě (radiolokační odrazivosti) cíle [20].




Obrázek 10: Pozice a pokrytí radarů CZRAD na území ČR, Zdroj [20]

Meteorologická měření se skládají z cca 10-20 otáček antény v azimutu s proměnným výškovým úhlem (elevací). Snímky jsou poskytovány v 15 minutových intervalech.

V ČR se nacházejí dva meteorologické radiolokátory, které tvoří síť CZRAD (viz obrázek 10), ve středních Čechách (Brdy u Prahy) a na střední Moravě (Skalky u Protivanova). V roce 2001 došlo k modernizaci jejich SW a horizontální rozlišovací schopnost sítě je od té doby 1 km do vzdálenosti 256 km, vertikální pak 0,5 km do vzdálenosti 14 km.

Dlouhodobým problémem je fakt, že radary operují na stejných frekvencích (5630 a 5645 MHz), na kterých je provozována i 802.11a (standard pro lokální bezdrátové sítě Wi-Fi). Dle individuálního oprávnění ČTÚ je pro radary vyhrazen kmitočet 5630 až 5660 MHz a je službou prioritní, zatímco Wi-Fi je službou podružnou a tedy negarantovanou. Aby se odrazy alespoň částečně podařilo minimalizovat, jsou snímky filtrovány, ale i tak se docela často na snímcích problém projevuje, viz obrázek 11.



Obrázek 11: Radarový snímek; výseče označují rušení Wi-Fi signálem

## 5.2 Zpracování dat pro učení

Samotné radarové snímky jsou i při svém malém rozlišení relativně velké a nelze je obsáhnout najednou celou neuronovou sítí, aniž by nebylo její naučení příliš časově náročné.


Vodní masy jsou na radarových snímcích reprezentovány hodnotou radiolokační odrazivosti (dBZ) a to v intervalu 4 - 60dBZ (stupnice je vidět na obrázku 11) s krokem 4dBZ. Tyto hodnoty bylo třeba pro učení neuronových sítí převést do intervalu  $\langle 0, 1 \rangle$ , aby na ně mohla být použita aktivační funkce.

### 5.2.1 $R$ -point metoda


Pro získání trénovacích množiny pro učení neuronové sítě byl použit následující postup: zvolíme bod a jeho okolí určité velikosti v několika časových úsecích a tvoříme jednotlivé posloupnosti změn v této oblasti. Těchto posloupností je podstatně méně než všech bodů na radarovém snímku, neboť se určité situace opakují. Tím je zaručeno, že při rozumném nastavení rádiusu, je trénovací množina dostatečně malá i popisná k tomu, aby učení skončilo v rozumné době s odpovídajícími výsledky.

Pro jeden snímek bude k vzorku získáno  $(1 + 2r)^2$  hodnot, kde  $r$  je rádius a znamená kolik bodů okolo trénovaného bodu bude zahrnuto, např. pro rádius  $r = 1$  bude pro popis vzorku z jednoho snímku získáno 9 hodnot (hodnota bodu a 8 jeho okolních bodů), pro  $r = 2$  pak 25 hodnot (hodnota bodu a 24 okolních). Okolí bodu je navíc výhodnější kvantizovat přírůstky (respektive úbytky) v daných bodech oproti předchozímu snímku [15], než jen jeho samotnou hodnotu. Jak je rozdíl v okolních bodech získán je naznačeno na obrázku 12.

Pro samotné učení je potřeba mít v trénovací vzorku minimálně dva časové vzorky  $b(b_{t-1}$  a  $b_t$ ) a alespoň jeden vzorek předpovědi  $b_{t+1}$ , který představuje pouze hodnotu, kterou daný bod má mít v čase  $t + 1$ . Při dodání pouze jednoho časového vzorku  $b_t$  není popis vývoje v bodě dostatečně velký a síť není schopna efektivní předpovědi, jak bude ukázáno dále v kapitole 6.3.



Obrázek 12: Bod a rozdíl okolních bodů z předchozího snímku, pro rádius  $r = 1$



Obrázek 13: Vstupní a výstupní data pro jeden trénovací vzorek

### 5.3 Ověření předpovědi

Pro ověření míry přesnosti předpovězených snímků byla využita metoda výpočtu  $F$ - $Score$  popsaná v kapitole 4.1.1. Ta však sama o sobě dá jen informaci o tom, zda v bodech snímků podle očekávání přšlo či ne, a proto byly definovány dvě další dílčí hodnoty.

Celková chyba  $SampleE$  je procentuální chyba, přesněji rozdíl předpovězeného množství proti reálné situaci, a je popsána následovně:

$$SampleE = \frac{|R_p - R_a|}{R_a}, \quad \text{kde} \quad R = \sum_{i=1}^M x_i,$$

kde  $M$  je množina všech bodů na snímku,  $x_i$  je hodnota intenzity bodu,  $R_p$  je suma intenzit na předpovídaném snímku a  $R_a$  je skutečná suma intenzit.


Další ukazatel  $PointE$  je absolutní hodnota průměrné chyby předpovědi bodu na snímku a je vypočtena takto:

$$PointE = \frac{\sum_{i=1}^M \delta_i}{M}, \quad \text{kde} \quad \delta = \begin{cases} |x_p - x_a| & \text{pro } x_a > 0 \\ x_p & \text{pro } x_a = 0 \end{cases},$$

kde  $M$  je opět množina všech bodů na snímku,  $x_p$  je předpovězená intenzita bodu a  $x_a$  je skutečná intenzita bodu.

### 5.4 Rozdělení dat


Pro získání trénovacích a testovacích dat byly využity kompletní radarová data za roky 2012 a 2013. Nejvíce deštivými měsíci v roce bývají obvykle měsíce letní, které také navíc obsahují největší množství silných přeháněk (tedy bouřek). Dalšími vhodnými zdroji dat jsou zimní měsíce na počátku a konci roku (viz obrázek 14).



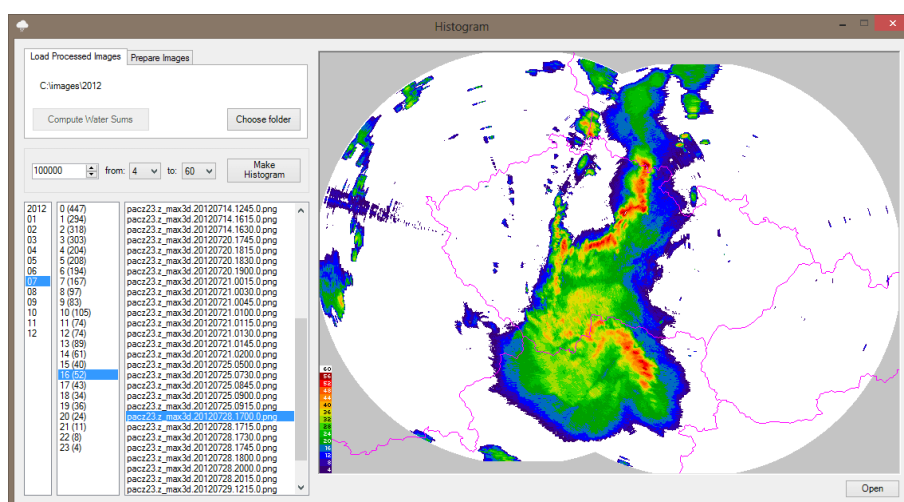
Obrázek 14: Úhrny srážek za rok 2012 a 2013 v mm, zdroj dat [21]

Aby bylo v radarových snímcích jednodušší najít podobné situace vhodné pro měření, byla vytvořena aplikace (viz obrázek 16), která nejprve umožnila zaindexování srážek na jednotlivých snímcích. Z těchto dat jsme pak schopni vytvořit histogramy a vybírat situace k učení a testování.

Na obrázku 15 je vidět rozložení měsíční intenzity radarových snímků vztažené poměrově k nejintenzivnějšímu měsíci série (7/2012). Je vidět jistá podobnost s průběhy úhrnu srážek. Rozdíl je způsoben nejen tím, že v radarovém snímku je zahrnuta i oblast mimo republiku, způsobem měření, ale také tím, že voda v mracích nemusí nad územím vždy spadnout jako srážky.



Obrázek 15: Rozložení intenzity odrazivosti pro roky 2012 a 2013



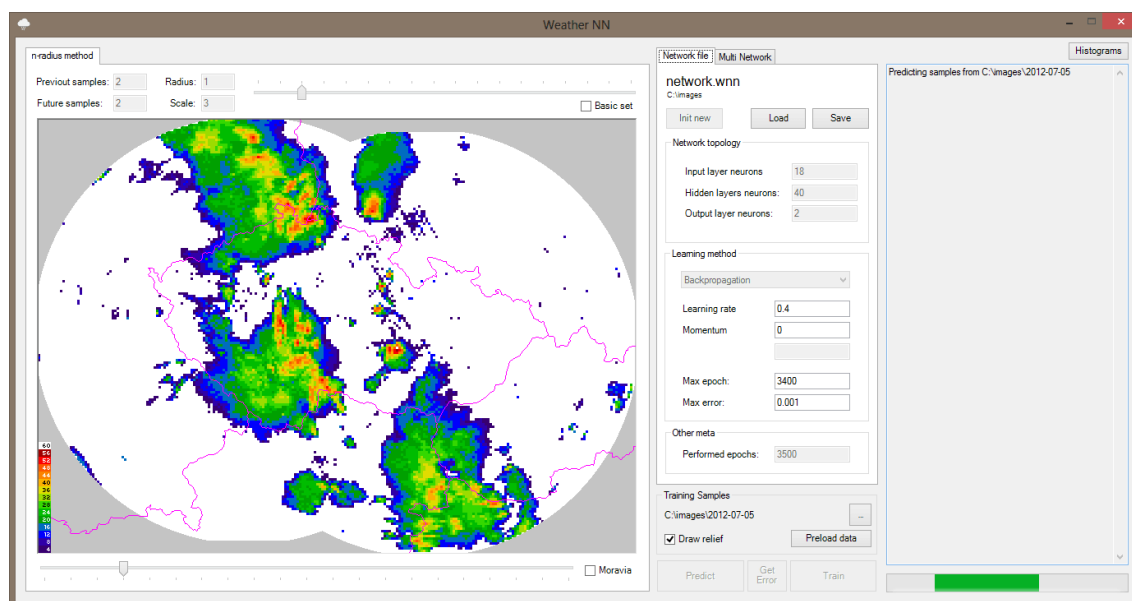
Obrázek 16: Program pro získání a rozdělení intenzit ve snímcích



## 5.5 Implementace neuronových sítí

Pro implementaci funkcí zpracovávajících data, jejich vizualizaci (viz obrázek 17) a interakci s neuronovými sítěmi bylo využito jazyka C#. Pro implementaci samotných učících algoritmů a neuronových sítí byl však zvolen C++, kterým je možné dosáhnout při elementárních úpravách hodnot v polích vah vyššího výpočetního výkonu, a také činí samotnou knihovnu neuronových sítí přenositelnou mezi různými prostředími.

Jako aktivační funkce byla zvolena sigmoida (viz kapitola 2.4.3), protože je výpočetně jednodušší než hyperbolický tangens, který byl při prvních testech časově neúměrně složitější.



Obrázek 17: Rozhraní pro práci s neuronovými sítěmi

## 6 Testování

V následující části se zaměříme na samotné testování učících metod. Nejprve bude jejich funkce otestována na testovacím generátoru oblačnosti a následně bude provedena série testů nad reálnými daty.

Pro zachycení časového kontextu je pro běžnou dopřednou neuronovou síť třeba nainicializovat  $(1 + 2r)^2 \times samples$  vstupů, kde *samples*, představuje počet snímků z kterých síť předpovídá, tedy pro nastavení  $r = 1, samples = 2$  je nutné vytvořit síť s 18 vstupy. Výstupní vrstva má pak velikost shodnou s počtem předpovídaných snímků. U rekurentní neuronové sítě jsou související snímky součástí učebního vzorku a jsou učeny postupně. Pro  $r = 1, samples = 2$  tedy rekurentní síť potřebuje pouze 9 vstupů s tím, že trénovací množina obsahuje dvě dvojice vstup-výstup (9-1) pro jeden trénovací vzorek.

Kvůli výše popsaným nárokům na velikost sítí jsou v testech data získána spojením dvou předchozích snímků a předpovídají vždy dva snímky následující.

### 6.1 Ověření metod na testovacím generátoru

Abychom ověřili správnou funkčnost učících algoritmů, vyvinuli jsme jednoduchý generátor náhodné pohybující se oblačnosti, na kterém byly postupně algoritmy prozkoušeny.

Získaná data dokázala, že všechny učící algoritmy jsou schopné neuronovou síť naučit nejen předpověď pohybu, ale jak naznačuje tabulka 2 i dostatečně přesně určit hodnoty pro splnění *F-Score*. Chyby intenzit snímku se pohybovaly kolem  $\approx 0,01$ , což je chyba zhruba 1% a jejich rozdíly mezi učebními metodami neměly v tomto testu zatím žádnou větší výpovědní váhu. Nejlépe si v testu vedla BP.

Alg.	<i>BP</i>	<i>RNN</i>	<i>SA</i>
<i>Precision</i> <sub><i>t</i>+1</sub>	1,000	1,000	0,965
<i>Precision</i> <sub><i>t</i>+2</sub>	0,959	0,957	0,922
<i>Recall</i> <sub><i>t</i>+1</sub>	0,999	0,995	0,998
<i>Recall</i> <sub><i>t</i>+2</sub>	0,962	0,949	0,975
<i>F-Score</i> <sub><i>t</i>+1</sub>	0,999	0,998	0,981
<i>F-Score</i> <sub><i>t</i>+2</sub>	0,961	0,953	0,948

Tabulka 2: Hodnoty naměřené na testovacích datech pro 2 budoucí snímky

### 6.2 První testování a Wi-Fi rušení

V prvním testu nad skutečnými snímky byly naučeny vzorky s posloupností celkem 37 snímků (což představuje zhruba 10 h) vyvíjející se silnější oblačností. Naučené sítě pak byly otestovány na 12 snímcích (asi 3 h) oblačnosti podobného charakteru ovšem pohybující se v jiném směru. Tato série pak byla použita i pro další testy s různými parametry při hledání jejich optimálního nastavení.

Hodnoty předpovědi podle očekávání na reálných datech klesly. Rozdíly mezi algoritmy učení jsou především výrazné při porovnání přesnosti padlých srážek, kde si nejlépe vede BP, rekurentní síť podává o něco uspokojivější výsledek v přesnosti množství srážek (viz graf 18). Simulované žíhání je velmi nepřesné, zato množství korektních hodnot srážek je poměrně vyšší, než u obou předchozích metod, což je vidět na grafu 19, kde je celková chyba množství srážek u SA téměř nulová a průměrná chyba bodu je také nejnižší ze všech testovaných.

Na testovaných snímcích se také vyskytují rušení zmíněná v kapitole 5.1 a vyobrazená na radarovém snímku (viz obrázek 11). Snímky proto byly ručně „vyčištěny“ a bylo nad nimi pro srovnání opět provedeno testování. Jak jasné ukazuje tabulka 3 působí tyto anomálie ve snímcích značné zhoršení tzv. *Precision*. Je to způsobeno tím, že se tyto odrazy objevují náhodně, mizí velmi rychle a síť, očekávající oblačnost, na to není schopna dostatečně rychle reagovat. Na celkovou hodnotu *F-Score* však tyto hodnoty nemají tak velký vliv, jak je vidět na příslušném srovnání v grafech 18 a 19. Nejsilnější zlepšení hodnoty způsobilo vyčištění snímků jen u metody SA. Na hodnoty chyb snímku a bodu nemá odstranění rušení také v podstatě žádný vliv.


	Wi-Fi rušení			Vyčištěno		
Alg.	BP	RNN	SA	BP	RNN	SA
$Precision_{t+1}$	0,834	0,807	0,643	0,863	0,908	0,712
$Precision_{t+2}$	0,775	0,673	0,579	0,792	0,829	0,638
$Recall_{t+1}$	0,793	0,807	0,910	0,829	0,749	0,929
$Recall_{t+2}$	0,689	0,766	0,858	0,728	0,638	0,875
$F-Score_{t+1}$	0,813	0,807	0,753	0,846	0,821	0,806
$F-Score_{t+2}$	0,729	0,716	0,691	0,759	0,721	0,738
$SampleE_{t+1}$	0,331	0,073	0,007	0,325	0,081	0,032
$SampleE_{t+2}$	0,511	0,175	0,004	0,502	0,198	0,034
$PointE_{t+1}$	0,233	0,232	0,160	0,227	0,226	0,166
$PointE_{t+2}$	0,282	0,231	0,182	0,277	0,236	0,192

Tabulka 3: Hodnoty pro dva budoucí snímky při testování na reálných datech


### 6.3 Rádus vzorku $r$ -point metody

$R$ -point metoda, která kromě bodu posílá i okolí bodu, má zlepšit konvergence sítě a jejich schopnost předpovědi. Následujícím test porovnává jaký má tento prvek vliv a jaká je vhodná velikost zvoleného rádusu. V tabulce 4 je srovnání výsledků pro testování rádusu  $r = \{0, 1, 2\}$ .

Konvergence a čas učení jsou hlavními rozdíly a jsou způsobeny jak trénovací množinou, která je pro větší radius vždy širší, tak topologií neuronové sítě, kdy je pro více vstupů nutné zavést i odpovídající velikost vnitřní vrstvy sítě. Pro radius  $r = 0$  při kterém nebere v potaz okolí bodu je velmi jasné vidět, že první snímek je relativně dobře předpovězen. Druhý snímek má ale již značné potíže, to je vidět i ve srovnání v grafu 20,



Obrázek 18: Graf porovnání  $F$ -Score na rušených a vyčištěných snímcích





Obrázek 19: Graf porovnání  $SampleE$  a  $PointE$  na rušených a vyčištěných snímcích

kde jsou hodnoty  $F$ -Score u RNN i SA velmi nízké. Mnohem výraznější jsou však rozdíly při pohledu na chyby intenzit v grafu 21. Pro rádius 0 jsou hodnoty  $PointE$  výrazně vyšší, to ukazuje na mnohem menší přesnost předpovědi bodů oproti situacím, kdy je rádius zaveden. Ačkoliv je u rádiusu velikosti 1 u metody BP celková chyba druhého snímku nejvyšší z testovaných, jsou v celkovém kontextu chyby intenzit pro tento rádius nejmenší.

Pro síť s vyšším rádiusem ( $r > 0$ ) již není u druhého snímku tak výrazný propad  $F$ -Score a srovnáme-li jejich výsledky, jsou velmi podobné i u chyb intenzit snímku a bodu. Pro rádius  $r = 2$  však mnohonásobně narostla časová i paměťová náročnost a přitom nepřinesla žádné výrazné zlepšení.

Z výše uvedených měření tedy vyplývá, že nejvhodnější velikost pro učení  $r$ -point metodou je  $r = 1$ , která při relativně přijatelné velikosti sítě a časové náročnosti dodává uspokojivé výsledky.

		<i>F-Score</i>			<i>SampleE</i>			<i>PointE</i>		
Rádus	Čas	<i>BP</i>	<i>RNN</i>	<i>SA</i>	<i>BP</i>	<i>RNN</i>	<i>SA</i>	<i>BP</i>	<i>RNN</i>	<i>SA</i>
$r = 0$	$t + 1$	0,805	0,815	0,817	0,300	0,407	0,149	0,322	0,306	0,296
	$t + 2$	0,720	0,596	0,471	0,355	0,101	0,419	0,324	0,256	0,407
$r = 1$	$t + 1$	0,813	0,807	0,753	0,331	0,073	0,007	0,233	0,232	0,160
	$t + 2$	0,729	0,716	0,691	0,511	0,175	0,004	0,282	0,231	0,182
$r = 2$	$t + 1$	0,810	0,785	0,717	0,338	0,008	0,092	0,220	0,207	0,123
	$t + 2$	0,728	0,660	0,669	0,462	0,275	0,164	0,265	0,276	0,185

Tabulka 4: Srovnání *F-Score* pro rádus  $r = \{0, 1, 2\}$ Obrázek 20: Graf srovnání *F-Score* pro rádus  $r = \{0, 1, 2\}$ Obrázek 21: Graf srovnání *SampleE* a *PointE* pro rádus  $r = \{0, 1, 2\}$

## 6.4 Topologie neuronových sítí


V prvním testu byly pro učení použity sítě s jednou vnitřní vrstvou, přesněji s velikostmi vrstev 18-40-2 pro BP a SA a 9-20-2 pro rekurentní síť. V práci zabývající se trénováním neuronových sítí evolučními algoritmy je navrhována jako vhodná topologie sítě s 2 vnitřními vrstvami (přesněji 18-45-30-2)[15]. Zvětšením sítě o další vnitřní vrstvu dojde k rapidnímu zpomalení adaptace sítě. Tento test má ověřit, zda je přidání vnitřní vrstvy pro použité učební metody něčím přínosné či se vyplatí používat pouze jednu vnitřní vrstvu.

Neuronové sítě byly v tomto testu navrženy s následujícími topologiemi 18-40-35-2 pro BP a SA a 9-20-15 pro rekurentní síť.

	1 vnitřní vrstva			2 vnitřní vrstvy		
Alg.	BP	RNN	SA	BP	RNN	SA
$F-Score_{t+1}$	0,813	0,807	0,753	0,812	0,711	0,751
$F-Score_{t+2}$	0,729	0,716	0,691	0,729	0,614	0,697
$SampleE_{t+1}$	0,331	0,073	0,007	0,354	0,477	0,020
$SampleE_{t+2}$	0,511	0,175	0,004	0,483	0,524	0,006
$PointE_{t+1}$	0,233	0,232	0,160	0,234	0,340	0,161
$PointE_{t+2}$	0,282	0,231	0,182	0,273	0,358	0,179

Tabulka 5: Srovnání hodnot pro 1 a 2 vnitřní vrstvy

Učení neuronových sítí s 2 vnitřními vrstvami se ukázalo jako dosti problematické. Nejen, že samotné učení je delší, ale kvůli zvětšení počtu vah je potřeba pro konvergenci i více trénovacích iterací. Jak ukazuje tabulka 5, hodnoty výsledných metod se navíc nijak výrazně neliší od předpovědi pomocí sítí s pouze jednou vnitřní vrstvou.



Obrázek 22: Grafy srovnání  $F-Score$  a chyb pro sítě s 2 vnitřními vrstvami

Předpovědní přesnost rekurentní sítě se pro dvě vnitřní vrstvy podstatně zhoršila (viz graf 22) a může za to zřejmě příliš výrazný vliv rekurentních neuronů, který se přidáním vrstvy zesílil.

Při učení radarových snímků metodami popisovanými v této práci se tedy ukázala jako výhodnější topologie s jednou vnitřní vrstvou.

## 6.5 Velikost učených snímků (trénovací množiny)


V dosavadních testech byla trénovací množina stanovena ze snímků, jejichž velikost odpovídala třetině velikosti vstupního radarového snímku. To na dané množině vstupů vytvořilo pro naučení sítě s rádiusem  $r = 1$  celkem 606 820 trénovacích vzorů.

Zmenšením snímku na  $scale = 9$ , tedy  $1/9$ , dojde k razantnímu zmenšení této množiny na 75 214 vzorů, což samozřejmě vede k rychlejšímu a kratšímu učení. Účelem tohoto testu bylo zjistit, zda to nějak výrazně ovlivní výsledky učení. Tabulka 6 ukazuje, že v případě  $F-Score$  ke zlepšení předpovědi nedošlo. Na graf 23 je vidět, že došlo k výraznější zlepšení celkové předpovědi intenzity pro BP, pro ostatní metody však zmenšení  $scale$  nic navíc nepřináší.

Největším problémem se při učení menšího počtu vzorků stala nestabilita rekurentní sítě, u které bylo naučení vzorků problematické a muselo být několikrát opakováno, než bylo její výsledek možno porovnat.

Scale	3			9		
Alg.	BP	RNN	SA	BP	RNN	SA
$Precision_{t+1}$	0,834	0,807	0,643	0,802	0,794	0,685
$Precision_{t+2}$	0,775	0,673	0,579	0,744	0,724	0,559
$Recall_{t+1}$	0,793	0,807	0,910	0,813	0,799	0,890
$Recall_{t+2}$	0,689	0,766	0,858	0,714	0,712	0,847
$F-Score_{t+1}$	0,813	0,807	0,753	0,807	0,797	0,774
$F-Score_{t+2}$	0,729	0,716	0,691	0,729	0,718	0,673
$SampleE_{t+1}$	0,331	0,073	0,007	0,211	0,040	0,008
$SampleE_{t+2}$	0,511	0,175	0,004	0,377	0,185	0,051
$PointE_{t+1}$	0,233	0,232	0,160	0,219	0,247	0,176
$PointE_{t+2}$	0,282	0,231	0,182	0,257	0,271	0,183

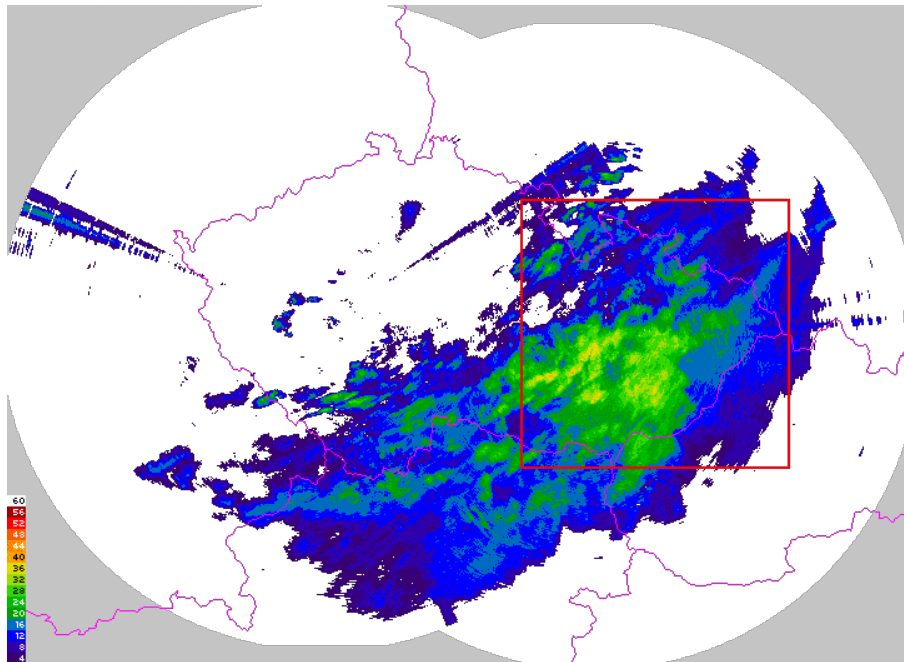
Tabulka 6: Hodnoty předpovědí pro velikosti snímků se scale {3, 9}



Obrázek 23: Graf srovnání chyby snímku a bodu pro velikosti snímků se scale {3, 9}

## 6.6 Předpověď na menší oblasti snímku

Trénovaná oblast dat vztažena na celou republiku představuje ohromné množství dat, pro jehož naučení v původní velikosti ( $1px = 1km^2$ ) by bylo potřeba mnoho procesorového času. Proto byla v učených snímcích zvolena menší oblast, pro kterou byla učená plná velikost snímku (viz obrázek 24).




Obrázek 24: Maska pro učení v plné velikosti snímku

Scale	1			3		
Alg.	<i>BP</i>	<i>RNN</i>	<i>SA</i>	<i>BP</i>	<i>RNN</i>	<i>SA</i>
$Precision_{t+1}$	0,863	0,890	0,797	0,851	0,841	0,733
$Precision_{t+2}$	0,768	0,799	0,718	0,759	0,700	0,634
$Recall_{t+1}$	0,894	0,788	0,920	0,905	0,893	0,968
$Recall_{t+2}$	0,869	0,675	0,907	0,878	0,894	0,972
$F-Score_{t+1}$	0,878	0,836	0,854	0,877	0,866	0,834
$F-Score_{t+2}$	0,815	0,732	0,801	0,814	0,758	0,767
$SampleE_{t+1}$	0,220	0,343	0,186	0,239	0,003	0,046
$SampleE_{t+2}$	0,293	0,466	0,097	0,336	0,029	0,239
$PointE_{t+1}$	0,214	0,266	0,200	0,206	0,224	0,170
$PointE_{t+2}$	0,233	0,302	0,209	0,226	0,218	0,184

Tabulka 7: Hodnoty pro testování nad výřezem radarového snímku pro scale  $\{1, 3\}$



Naučení na menší oblasti, které umožnilo předpověď v plné velikost, bylo porovnáno s předpovědí menší oblasti neuronové sítě naučené na celém snímku. Při porovnání hodnoty přesnosti předpovědi  $F-Score$  byla změna výraznější jen nepatrně u RNN a SA metody učení, jak je možno vidět v tabulce 7. Z grafu 25 vyplývá, že v případě vyššího rozlišení se zlepšila celková předpovídaná hodnota u BP, rekurentní síť však oproti tomu podstatně zhoršila svou predikci. U simulovaného žihání se zlepšila předpověď pro druhý snímek. Celkově však ani zvýšení rozlišení radarového snímku není faktorem, který by pozitivně ovlivnil učení a predikci sítí.



Obrázek 25: Graf srovnání chyby u výřezu snímku pro scale  $\{1, 3\}$

## 6.7 Předpověď s vyšším rozlišením než trénovaným

Veškeré faktory, které ovlivňovaly předpověď sítě, se v předchozích testech vždy vztahovaly k velikosti trénovací množiny. Dosavadní testy ukazují jako optimální nastavení sítě pro učení hodnoty s rádiusem  $r = 1$  a rozlišením  $scale = 3$ . Metoda získávání dat pro předpověď však umožňuje získat data ze snímku nezávisle na rozlišení. V následujícím testu tedy byly sítě naučené na nižším rozlišení nastaveny tak, aby předpovídaly z plného rozlišení radarového snímku.


Tímto testem prošly bez větších potíží metody učení BP a SA, jak je vidět v tabulce 8, a hodnoty parametrů se přibližují učenému rozlišení. Rekurentní síť však díky svému dynamickému charakteru nebyla schopna z většího množství dat vhodně předpovídat (její paměťová část není schopná zvětšení reflektovat) a její data proto nejsou použitelná.

Čas	$F-Score$		$SampleE$		$PointE$	
	BP	SA	BP	SA	BP	SA
$t + 1$	0,815	0,770	0,322	0,022	0,233	0,172
$t + 2$	0,733	0,704	0,497	0,022	0,277	0,190

Tabulka 8: Srovnání  $F-Score$ ,  $SampleE$  a  $PointE$  pro zvětšené rozlišení předpovědi

## 6.8 Paměť a generalizace neuronových sítí

Následující test by měl zjistit, zda je předpověď podobného postupu oblačnosti, který byl někdy síti předložen, lepší oproti předložení neznámého a také, zda jsou sítě schopné generalizace.



Obrázek 26: Testované běžné oblačnosti


Nejprve byly sítím postupně předloženy k naučení tři situace přechodu podobné oblačnosti z února 2012. Testování předpovědi bylo pak následně provedeno na podobné situaci z prosince 2013 (viz 26a) a na situaci z ledna (viz 26b) téhož roku, kdy sice masa postupovala přes republiku zhruba se stejnou intenzitou avšak zcela jiným směrem. Třetí je pak situace z března 2013 (viz 26c), jedná se o kupovitou oblačnost s kterou se neuronové sítě při učení vůbec nesetkaly.

	obdobná (12/2013)			jiný směr (1/2013)			kupovitá (3/2013)		
Alg.	<i>BP</i>	<i>RNN</i>	<i>SA</i>	<i>BP</i>	<i>RNN</i>	<i>SA</i>	<i>BP</i>	<i>RNN</i>	<i>SA</i>
$Precision_{t+1}$	0,856	0,690	0,750	0,878	0,712	0,764	0,430	0,227	0,313
$Precision_{t+2}$	0,800	0,648	0,713	0,814	0,615	0,717	0,387	0,189	0,273
$Recall_{t+1}$	0,823	0,871	0,921	0,870	0,892	0,935	0,447	0,700	0,734
$Recall_{t+2}$	0,758	0,823	0,876	0,819	0,846	0,897	0,384	0,656	0,710
$F-Score_{t+1}$	0,839	0,770	0,827	0,874	0,791	0,841	0,438	0,342	0,439
$F-Score_{t+2}$	0,779	0,725	0,786	0,817	0,712	0,797	0,386	0,293	0,395
$SampleE_{t+1}$	0,317	0,263	0,034	0,285	0,249	0,071	0,342	1,572	0,595
$SampleE_{t+2}$	0,402	0,111	0,002	0,338	0,069	0,079	0,407	1,303	0,754
$PointE_{t+1}$	0,219	0,232	0,172	0,194	0,200	0,149	0,249	0,152	0,139
$PointE_{t+2}$	0,246	0,215	0,201	0,224	0,182	0,179	0,258	0,122	0,135


Tabulka 9: Výsledky testu pro obdobnou, generalizovatelnou a neznámou situaci

Výsledky testu, které podrobně popisuje tabulka 10, na první pohled ukazují, že první dvě situace, tedy totožná a podobná situace se změnou směru, podávají velmi podobné výsledky. Naproti tomu neznámá situace (3/2013) propadá s přesností předpovědi srážek na polovinu, jak mnohem jasněji ukazuje graf 27, kde je dokonce vidět, že druhá situace, kdy jde oblačnost jiným, směrem je předpovězena o něco lépe.

Dá se tedy usuzovat, že naučená síť je schopna generalizace v určitých mezích. Situace z března 2013 je diametrálně odlišná, a proto i chyby intenzit deště několikanásobně převyšují hodnoty na snímku. Srovnání chyb intenzit (viz obrázek 28), ze kterých byla pro vysoké hodnoty kvůli čitelnosti odstraněna třetí situace, pak opět ukazuje na lepší výsledek druhého testu, ačkoliv rozdíl není příliš veliký.




Obrázek 27: Graf srovnání  $F$ -Score testované situace ve 6.8



Obrázek 28: Graf srovnání chyb  $SampleE$  a  $PointE$  pro situace 12/2013 a 1/2013

## 6.9 Intenzivní srážky

Zatím se v předpovědích a učení používala data z měsíců zimních a jarních, ve kterých se neobjevuje mnoho silných bouřek. Pro následující test byly proto vybrány data z červencových a srpnových měsíců, kdy i podle histogramu úhrnu srážek (viz obrázek 14 kapitola 5.4) je výskyt silných bouřek nejvyšší.



Obrázek 29: Testované bouřkové situace


Sítě byly opět učeny na datech z roku 2012, a to přesněji z července. Otestování probíhalo na dvou bouřkách z července a srpna 2013 (viz 29a a 29b). Jako třetí byla vybrána souvislá oblačnost z ledna 2013 (viz 29c), ve které se vyskytuje menší bouřka.

	7/2013			8/2013			1/2013		
Alg.	BP	RNN	SA	BP	RNN	SA	BP	RNN	SA
$Precision_{t+1}$	0,801	0,762	0,757	0,876	0,864	0,860	0,724	0,690	0,699
$Precision_{t+2}$	0,761	0,564	0,756	0,851	0,735	0,745	0,640	0,568	0,578
$Recall_{t+1}$	0,802	0,840	0,832	0,860	0,871	0,873	0,724	0,718	0,749
$Recall_{t+2}$	0,644	0,834	0,848	0,739	0,832	0,850	0,580	0,699	0,756
$F-Score_{t+1}$	0,801	0,799	0,793	0,868	0,868	0,866	0,724	0,704	0,723
$F-Score_{t+2}$	0,698	0,673	0,675	0,791	0,781	0,794	0,609	0,627	0,655
$SampleE_{t+1}$	0,018	0,039	0,001	0,023	0,027	0,019	0,006	0,113	0,045
$SampleE_{t+2}$	0,423	0,021	0,036	0,442	0,081	0,228	0,331	0,133	0,102
$PointE_{t+1}$	0,199	0,180	0,184	0,238	0,236	0,070	0,292	0,323	0,281
$PointE_{t+2}$	0,272	0,170	0,173	0,281	0,256	0,239	0,297	0,297	0,257


Tabulka 10: Výsledky testu pro snímky s bouřkami

Učení na snímcích s bouřkami se ukázalo jako velmi zajímavé, neboť BP i SA metoda, které doposud ukazovaly velké zobecnění intenzity srážek uvnitř mraku, zde v prvním předpovězeném snímku ukázaly velmi kvalitní předpovědi intenzit, jak je ostatně jasné z první série chyby (7/2013) na grafu 31.

U druhého snímku se už BP nepovedlo předpovědět bouřkové intenzity, a v předpovědi pro něj tedy chybí, což je vidět na vysoké chybě celkové intenzity. Rekurentní síť sice vykazuje určité zlepšení, její chyba však není učením na bouřkách ovlivněna tolik a dá se říct, že pracuje srovnatelně dobře jako na snímcích s nízkými intenzitami.



Obrázek 30: Graf srovnání  $F$ -Score testované situace s bouřkovými situacemi



Obrázek 31: Graf srovnání chyb  $SampleE$  a  $PointE$  pro bouřkové situace

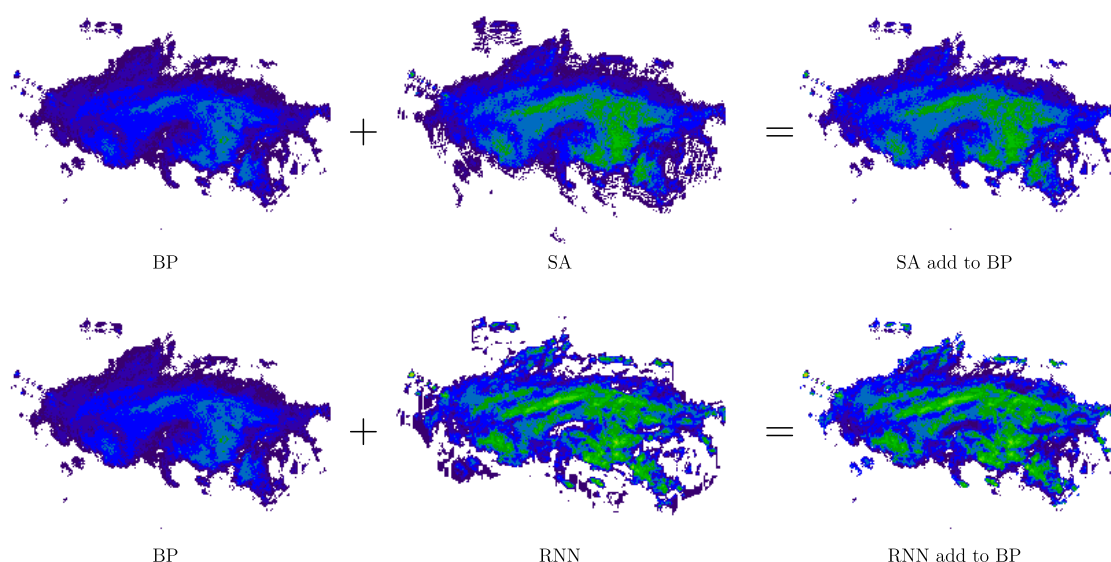
První bouřkové situace jsou vesměs velmi podobné, a proto jsou i jejich výsledky téměř totožné. Ačkoliv se třetí testovaná situace svým charakterem výrazně liší, i ta je generalizována z naučených bouřkových snímků relativně dobře, jak je vidět na sice nižších, ale stále přijatelných hodnotách  $F$ -Score, tak na chybách intenzit, viz poslední série chyb na obrázku 31.

Tento test tedy ukazuje, že přítomnost bouřkových dat při učení (respektive v trénovací množině) může pomoci generalizaci a přesnosti předpovědi neuronových sítí.

## 6.10 Skládání výsledků neuronových sítí

Všechny metody učení v průběhu provedených testů vykazovaly určité charakteristické rysy. BP v téměř naprosté většině případů nejlépe určí hodnotu  $F$ -Score, která určuje jak dobře sítě předpovídají místo dopadu srážek. V případě intenzit je však její bilance nejhorší. Simulované žíhání oproti tomu po většinu času velmi přesně určí množství srážek, na druhou stranu je však neurčuje přesně polohově. Rekurentní síť má také problémy s určením kde se srážky budou vyskytovat, ale proti SA ukazuje mnohem lépe intenzity srážek. Její výhoda je v tom, že dokáže velmi dobře určit extrémy, což se pak nejvíce pozitivně projevilo u bouřkových snímků.

Nabízí se tedy myšlenka, že kombinací těchto výstupů by se dala vylepšit celková předpověď snímku a to tak, že SA či RNN budou přispívat hodnotami do výsledků, které dodá metoda BP.



Obrázek 32: Ukázka použití masky RNN a SA pro BP

Jak je vidět na obrázku 32, hodnoty BP jsou zvýšeny, pokud v maskách snímků dodaných RNN či SA je hodnota intenzity vyšší. V opačném případě se ponechá původní hodnota získaná výpočtem sítě učené pomocí BP. Toto také způsobí, že všechny nežádoucí vzruchy metod RNN a SA, které vznikly na snímcích se ořežou. Snímek má proto shodnou hodnotu  $F$ -Score se snímkem dodaným BP, ale zlepší se hodnoty intenzit na snímku, které jsou právě u BP nejhorší.

Toto spojení výsledků bylo vyzkoušeno na dvou situacích, na kterých by se mohlo ukázat, zda má kombinace výstupů dostatečné praktické uplatnění.


### 6.10.1 Běžná oblačnost

První testovanou situací je klasická oblačnost, se kterou měla BP, co se týkalo chyb intenzit, vždy největší potíže. Hodnoty týkající se  $F$ -Score v tabulce 11 jsou nezajímavé, jelikož pouze kopírují hodnoty běžné BP.

Mnohem zajímavější jsou pak hodnoty reflektující chyby snímku, kde díky kombinaci s rekurentní sítí a SA došlo k razantnímu zlepšení. Konkrétně kombinace BP+SA se díky tomu v intenzitách snímku blíží téměř bezchybné předpovědi. I kombinace s rekurentní sítí podává mnohem lepší výsledky, pokud ji porovnáme s každou ze spojených metod samostatně. Jak vypadají spojení snímků je vidět na obrázku 41.

Alg.	BP	RNN	SA	BP + RNN	BP + SA
$Precision_{t+1}$	0,878	0,712	0,764	0,878	0,878
$Precision_{t+2}$	0,814	0,615	0,717	0,814	0,814
$Recall_{t+1}$	0,870	0,892	0,935	0,870	0,870
$Recall_{t+2}$	0,819	0,846	0,897	0,819	0,819
$F\text{-}Score_{t+1}$	0,874	0,791	0,841	0,874	0,874
$F\text{-}Score_{t+2}$	0,817	0,712	0,797	0,817	0,817
$SampleE_{t+1}$	0,285	0,249	0,034	0,155	0,010
$SampleE_{t+2}$	0,338	0,069	0,002	0,144	0,008
$PointE_{t+1}$	0,194	0,200	0,172	0,240	0,187
$PointE_{t+2}$	0,224	0,182	0,201	0,225	0,220

Tabulka 11: Srovnání hodnot pro normální a provázané metody předpovědi




Obrázek 33: Hodnoty chyb  $SampleE$  a  $PointE$  pro provázané metody masky

### 6.10.2 Bouřkové snímky

Druhou testovanou sérií jsou snímky s bouřkami, kde si BP vedla v prvním snímku velmi dobře. U druhého snímku však došlo ke zhoršení předpovědi, kvůli absenci bouřkových intenzit. V případě bouřkových snímků sice při kombinaci BP a RNN došlo ke zhoršení intenzit prvního předpovídaného snímku (viz tabulka 12), ale právě u druhého snímku došlo ke značnému zlepšení.

Alg.	<i>BP</i>	<i>RNN</i>	<i>SA</i>	<i>BP + RNN</i>	<i>BP + SA</i>
$Precision_{t+1}$	0,876	0,864	0,860	0,876	0,879
$Precision_{t+2}$	0,851	0,735	0,745	0,851	0,851
$Recall_{t+1}$	0,860	0,871	0,873	0,860	0,860
$Recall_{t+2}$	0,739	0,832	0,850	0,739	0,739
$F-Score_{t+1}$	0,868	0,868	0,866	0,868	0,868
$F-Score_{t+2}$	0,791	0,781	0,794	0,791	0,791
$SampleE_{t+1}$	0,023	0,027	0,019	0,086	0,010
$SampleE_{t+2}$	0,442	0,081	0,228	0,145	0,160
$PointE_{t+1}$	0,238	0,236	0,070	0,257	0,243
$PointE_{t+2}$	0,281	0,256	0,239	0,308	0,290

Tabulka 12: Srovnání hodnot provázané metody předpovědi nad bouřkovými snímky



Obrázek 34: Hodnoty chyb provázaných metod nad bouřkovými snímky

Předpověď snímku s bouřkovou situací pomocí BP má u druhého snímku problémy i s předpovědí  $F-Score$ , a tak ani hodnoty spojených metod BP a SA nejsou nijak výrazně lepší, než samotná metoda SA. Rekurentní síť je velmi citlivá, a proto při předpovědi bouřkových snímků hodnoty intenzity někdy příliš zvyšuje. Spojení výpočtu BP a rekurentní



sítě přenáší její extrémní hodnoty i do spojeného snímku, a tím v prvním i druhém snímku zvyšují celkovou chybu intenzit. Spojení předpovědí snímků je ukázáno na obrázku 42.

Všeobecně se dá říci, že spojování výstupů BP a rekurentní sítě je výhodnější u větší oblačnosti, ve které se nevyskytují přímo silné a intenzivně se měnící bouřky. Metoda SA sice zlepší celkovou intenzitu druhého předpovídaného snímku, předpověď však u druhého snímku také postrádá bouřkové extrémy.

## 7 Závěr

Cílem práce bylo porovnat jednotlivé učební metody neuronových sítí při predikci vývoje oblačnosti z radarových snímků a ukázat jejich schopnosti generalizace.

Během testování se jako nejlepší topologie sítě ukázala být síť s jednou vnitřní vrstvou, a to přesně s topologií 18-40-2 pro BP a SA a 9-20-2 pro rekurentní síť. Také byl ukázán pozitivní vliv započítávání okolních bodů při předpovědi, kde stačí pro dobrou předpověď okolí velikost  $1px$ . Při učení se jako nejvhodnější nastavení učících parametrů sítě ukázaly být hodnoty koeficientu učení  $\eta = 0,4$  a vlivu předchozího kroku  $\mu = 0,1$ .

Základní otestování metod proběhlo na testovacím generátoru oblačnosti, kde se předpovědní hodnoty *F-Score* snímků pohybovaly kolem hodnoty 1. Při testování nad skutečnými radarovými daty se pak hodnoty pro první snímek pohybovaly v rozmezí 0,7 až 0,8. Těchto hodnot většinou dosahovala síť učená pomocí BP. Předpověď dalšího časového snímku byla téměř vždy horší, a se zvyšováním počtu předpovídaných snímků se zhoršovala ještě razantněji. Pro tuto vlastnost, a s tím spojené vysoké časové náročnosti adaptace, byly v testech předpovídaný maximálně 2 snímky dopředu (tedy situace za 15 a 30 minut).

Dalšími faktory přesnosti předpovědi byly chyby intenzit srážek snímku *SampleE* a bodu *PointE*, viz kapitola 5.3. Při testování těchto parametrů se síť učená pomocí BP ukázala být pro změnu nejhorší. Síť učená metodou SA dosahovala podstatně lepších hodnot stejně jako rekurentní síť, která však při učení vyžadovala mnohem více času pro nastavení parametrů. Hodnoty intenzit rekurentní sítě se většinou nejvíce podobaly hodnotám na skutečném snímku.

Na základě výše popsaných informací byla dále vyzkoušena kombinace výstupu BP s dalšími metodami (viz kapitola 6.10), která zejména pro běžnou oblačnost značně snížila chyby předpovědi intenzit.

Rekurentní síť při učení projevovala svou základní vlastnost a to, že aproximuje dynamický systém, který je závislý na časovém kontextu předchozích vzorků. Její naučení bylo mnohdy velmi obtížné, i když relativně rychlé. Z algoritmů popsaných v práci má největší potenciál pro další zkoumání predikce radarových snímků pomocí popsané *r-point* metody. Perspektivním rozšířením jejího učení by byla automatizace a průběžná úprava parametrů na základě chyby sítě a ověřování hodnot predikce, aby se odstranila potřeba manuální úpravy při učení a co nejvíce zlepšila možná kvalita naučení.


Co se týče samotné *r-point* metody, ta se při správném nastavení ukázala být dostatečně použitelná pro krátkodobé předpovědi jednoho až dvou snímků. Ve spojení s vlastnostmi rekurentní sítě se však naskýtá rozšíření metody, které spočívá v zavedení informace o poloze bodu, který je předpovídan. Předpověď by se pak nezaměřovala na předpověď globální ale lokální, kde by se v okolí bodu určil rozumný radius, a pro učení by se použilo 6 a více snímků dozadu i dopředu. Rekurentní síť je velmi citlivá na extrémní a při vhodném naučení by mohla být schopna detekovat intenzivní srážky v daném bodě s hodinovým, ale i větším předstihem. Největší překážkou této realizace je nedostatek dat, kdy 2 roky snímků neposkytují dostatečné množství snímků, ve kterých by se daly nalézt pro jeden bod na mapě situace k učení a ověření. Další překážkou je také vysoká časová náročnost učení takto rozsáhlé sítě.

## 8 Reference


- [1] Abhisheka K., Singha M.P., Ghoshb S., Anandc A. *Weather forecasting model using Artificial Neural Network*, Procedia Technology 4 311–318, 2012.
- [2] Bengio Y., Simard P., a Frasconi P. *Learning long-term dependencies with gradient descent is difficult*, IEEE Transactions on Neural Networks (1994) 5(2):157–166.
- [3] Biskup, Roman. *Možnosti neuronových sítí*, Praha, 2009.
- [4] Doya, Kenji. *Bifurcations in the learning of recurrent neural networks*, Proceedings of IEEE International Symposium on Circuits and Systems (1992), 2777-2780.
- [5] Engel, Jonathan. *Teaching Feed-Forward Neural Networks by Simulated Annealing*, Complex Systems 2 (1988) [str. 641-648]
- [6] Hayati M., Mohebi Z. *Temperature Forcasting Based on Neural Network Approach*, World Applied Sciences Journal 2 (6): 613-620, 2007.
- [7] Heaton, Jeff. *Introduction to neural networks for C#*, 2nd ed. Heaton Research Inc, 2008, ISBN 1-60439-009-3.
- [8] Jaeger, Herbert. *Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the "echo state network" approach*. Report 159, German National Research Center for Information Technology, 2002
- [9] Kirkpatrick S., Gelatt Jr C. D., Vecchi, M. P. *Optimization by Simulated Annealing*, Science 220 (4598) (1983) [str. 671–680]
- [10] Kuba, Martin. *Neuronové sítě*, 1995.
- [11] Litta A. J., Idicula S.M., Mohanty U. C. *Artificial Neural Network Model in Prediction of Meteorological Parameters during Premonsoon Thunderstorms*, International Journal of Atmospheric Sciences Volume 2013, Article ID 525383
- [12] McCulloch W., Pitts W. *A logical calculus of the ideas immanent in nervous activity*, Bulletin of Mathematical Biophysics (1943) [str. 115-1333]
- [13] Rosenblatt, Frank. *The Perceptron—a perceiving and recognizing automaton*, Report 85-460-1, Cornell Aeronautical Laboratory (1957)
- [14] Toth E., Brath A., Montanari A. *Comparison of short-term rainfall prediction models for real-time flood forecasting*, Journal of Hydrology. vol. 239: Elseiver, s. 132-147, 2010.
- [15] Vitásek, Lukáš. *Predikce meteorologických jevů pomocí neuronových sítí*, VŠB-TU Ostrava, 2013.
- [16] Volná, Eva. *Neuronové sítě 1*, Ostravská univerzita, Ostrava 2002.

- 
- [17] Vondrak, Ivo. *Umělá inteligence a neuronové sítě*, VŠB-TU Ostrava, 2001, ISBN 80-7078-259-5
- [18] Wang P., Smeaton A., Lao S., O'Connor E, Ling Y. a O'Connor N. *Short-Term Rainfall Nowcasting: Using Rainfall Radar Imaging*, Eurographics Ireland, 2009.
- [19] Yam J.Y.F., Chow T.W.S. *A weight initialization method for improving training speed in feedforward neural network* Neurocomputing 30 (2000) 219-232
- [20] Radarová síť CZRAD, ČHMÚ [online]. [citace 30.3.2014], Dostupné na: [http://www.chmi.cz/files/portal/docs/meteo/rad/info\\_czrad/index.html](http://www.chmi.cz/files/portal/docs/meteo/rad/info_czrad/index.html)
- [21] Územní srážky, ČHMÚ [online]. [citace 6.4.2014], Dostupné na: [http://portal.chmi.cz/portal/dt?menu=JSPTabContainer/P4\\_Historicka\\_data/P4\\_1\\_Pocasi/P4\\_1\\_5\\_Uzemni\\_srazky](http://portal.chmi.cz/portal/dt?menu=JSPTabContainer/P4_Historicka_data/P4_1_Pocasi/P4_1_5_Uzemni_srazky)


## A Ukázky předpovědí




Obrázek 35: Předpověď běžné oblačnosti pomocí BP




Obrázek 36: Předpověď běžné oblačnosti pomocí RNN




Obrázek 37: Předpověď běžné oblačnosti pomocí SA



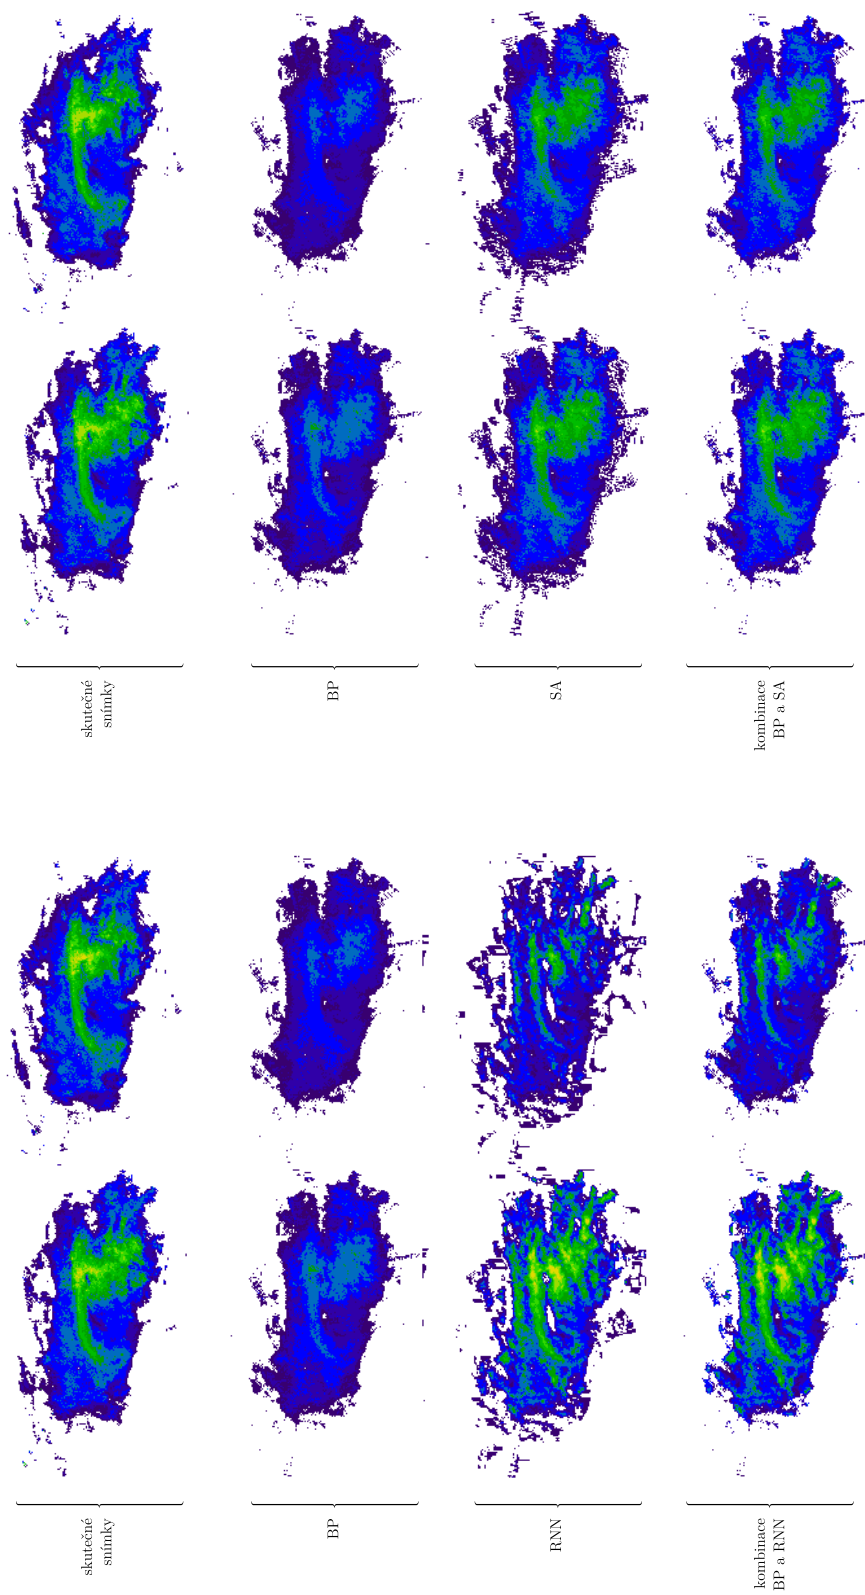
Obrázek 38: Předpověď bouřkové oblačnosti pomocí BP



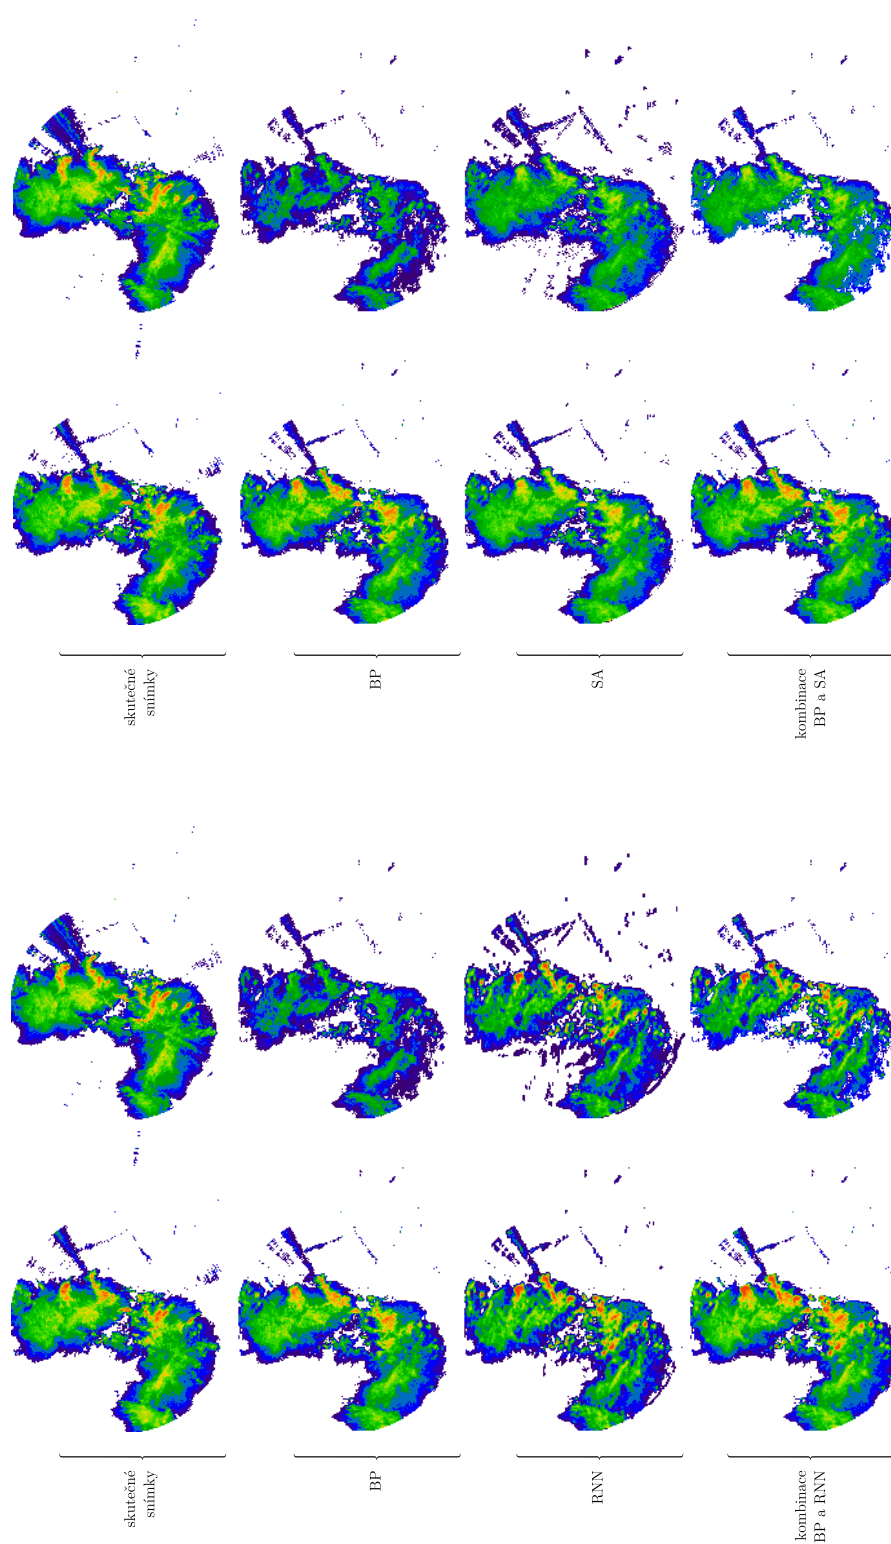
Obrázek 39: Předpověď bouřkové oblačnosti pomocí RNN



Obrázek 40: Předpověď bouřkové oblačnosti pomocí SA



Obrázek 41: Kombinace předpovědí BP s RNN a SA u běžné oblačnosti



Obrázek 42: Kombinace předpovědí BP s RNN a SA u bouřkové oblačnosti